PATENT ABSTRACTS OF JAPAN

(11)Publication number:

2002-049575

(43)Date of publication of application: 15.02.2002

(51)Int.CI.

G06F 13/14 G06F 3/06 G06F 12/00 G06F 12/16 G06F 13/00

(21)Application number: 2000-233291

(71)Applicant: HITACHI LTD

(22)Date of filing:

01.08.2000

(72)Inventor: ITO AKIHIRO

UTSUNOMIYA NAOKI

SONODA KOJI

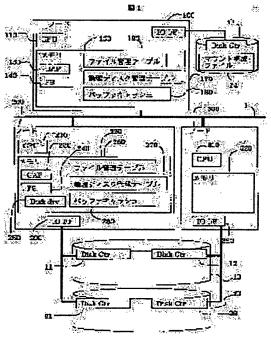
KUMAZAKI HIROYUKI

(54) FILE SYSTEM

(57)Abstract:

PROBLEM TO BE SOLVED: To provide a file system which can shorten the time needed for IO path switching and conceal IO path switching processing from general users.

SOLUTION: In this system which defines file IDs for every files, a file server FS refers to a file management table and finds a logical disk ID for accessing a file when a user application UAP makes a request to access while specifying the file ID of the file. Further, the file server refers to a logical disk management table to find the 10 path corresponding to the logical disk ID and uses the IO path to access a physical disk unit. If trouble occurs to the IO path of an in-operation system, the logical disk management tables of all nodes are rewritten to switch the 10 path.



LEGAL STATUS

[Date of request for examination]

18.07.2003

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision

(19)日本国特許庁(JP)

(12) 公開特許公報(A)

(11)特許出願公開番号 特開2002-49575 (P2002-49575A)

(43)公開日 平成14年2月15日(2002.2.15)

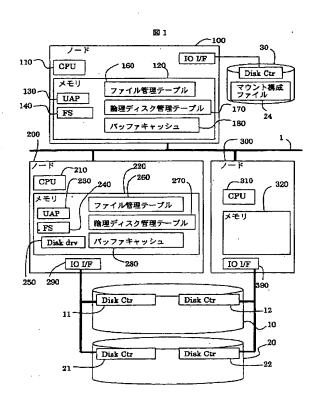
識別記号	FΙ	テーマコード(参考)		
3 1 0	G06F 13/14	310H 5B014		
3 0 4	3/06	304B 5B018		
5 1 4	12/00	514E 5B065		
3 1 0	12/16	310A 5B082		
3 0 1	13/00	301P 5B083		
	審査請求 未請求	請求項の数20 OL (全 26 頁)		
特願2000-233291(P2000-233291)	(71)出願人 000005	108		
	株式会	社日 立製作 所		
平成12年8月1日(2000.8.1)	東京都千代田区神田駿河台四丁目6番地			
J	(72)発明者 伊藤	昭博		
•	神奈川	県川崎市麻生区王禅寺1099番地 株		
	式会社	日立製作所システム開発研究所内		
	(72)発明者 宇都宮	直樹		
	神奈川	県川崎市麻生区王禅寺1099番地 株		
	式会社	日立製作所システム開発研究所内		
·	(74)代理人 100078	134		
	弁理 士	武 顕次郎		
		最終頁に続く		
	3 1 0 3 0 4 5 1 4 3 1 0 3 0 1 特願2000-233291(P2000-233291)	3 1 0 3/06 3/06 3/06 12/00 3 1 0 12/16 3 0 1 13/00 審查請求 未請求 *** 特願2000-233291(P2000-233291) (71)出願人 000005 株式会平成12年8月1日(2000.8.1) (72)発明者 伊藤 神奈川 式会社 (72)発明者 宇都宮 神奈川 式会社		

(54) 【発明の名称】 ファイルシステム

(57)【要約】

【課題】 IOパス切り替えのために要する時間を短縮し、一般ユーザからIOパス切り替え処理を隠蔽することのできるファイルシステム。

【解決手段】 ファイル毎にファイルIDが定義されているシステムにおいて、ユーザアプリケーションUAPからのファイルIDを指定したアクセス要求に対して、ファイルサーバFSはファイル管理テーブルを参照し、そのファイルをアクセスするための論理ディスクIDを求める。ファイルサーバは、さらに、論理ディスク管理テーブルを参照し、論理ディスクIDに対応するIOパスを求め、そのIOパスを使って物理ディスク装置にアクセスする。運用系のIOパスに障害発生時、全ノードの論理ディスク管理テーブルを書き換えることによってIOパスの切り替えを行う。



【特許請求の範囲】

【請求項1】 ファイル毎にファイルIDが定義されて おり、複数の物理ディスク装置に分散管理されたファイ ルの処理を行う1または複数のファイルサーバを有する ファイルシステムにおいて、ファイルID及び該ファイ ルIDに対応するファイルが格納されている論理ディス クの論理ディスクIDを含むファイル管理テーブルと、 論理ディスク I D 及び前記論理ディスクに対応する1つ 以上の物理ディスク装置にアクセスするための1つ以上 のIOパスを含む論理ディスク管理テーブルとを備え、 ユーザからのファイルIDを指定したファイルへのアク セス要求を受信したファイルサーバは、ファイル管理テ ーブルを参照し、前記ファイルIDから前記ファイルが 格納されている論理ディスクの論理ディスクIDを決定 し、論理ディスク管理テーブルを参照して前記論理ディ スクIDから前記論理ディスクに対応する物理ディスク 装置にアクセスするためのIOパスを決定し、決定した IOパスを使用して物理ディスク装置にアクセスするこ とを特徴とするファイルシステム。

ネットワークに接続されたそれぞれの内 【請求項2】 部にファイルサーバが構成された複数のノードと、複数 のノードの少なくとも2つのノードに共通に接続された 物理ディスク装置とを備え、ファイル毎にファイルID が定義されており、前記複数の物理ディスク装置に分散 管理されたファイルの処理を行うファイルシステムにお いて、複数のノードのそれぞれは、ファイルID及び前 記ファイルIDに対応するファイルが格納されている論 理ディスクの論理ディスクIDを含むファイル管理テー ブルと、論理ディスクID及び前記論理ディスクに対応 する1つ以上の物理ディスク装置にアクセスするための 1つ以上の I Oパスを含む論理ディスク管理テーブルと を備え、ユーザからのファイルIDを指定したファイル へのアクセス要求を受信したファイルサーバは、ファイ ル管理テーブルを参照し、前記ファイルIDから前記フ ァイルが格納されている論理ディスクの論理ディスクI Dを決定し、論理ディスク管理テーブルを参照して前記 論理ディスク I Dから前記論理ディスクに対応する物理 ディスク装置にアクセスするためのIOパスを決定し、 決定した I Oパスを使用して物理ディスク装置にアクセ スすることを特徴とするファイルシステム。

【請求項3】 前記 I Oパスを特定する情報は、ノード番号、I Oインターフェイス番号及びディスクコントローラ番号からなることを特徴とする請求項2記載のファイルシステム。

【請求項4】 前記ファイルIDから決定した論理ディスクIDに対応する物理ディスク装置が、他のノードであるリモートノードに接続されている場合、自ノードのファイルサーバは、前記リモートノードにアクセス要求を送信し、前記アクセス要求を受信した前記リモートノードのファイルサーバが前記物理ディスク装置に格納さ

れた該当ファイルにアクセスすることを特徴とする請求 項3記載のファイルシステム。

【請求項5】 ネットワークに接続されたそれぞれの内 部にファイルサーバが構成された複数のノードと、複数 のノードの少なくとも2つのノードに共通に接続された 物理ディスク装置とを備え、ファイル毎にファイルID が定義されており、前記複数の物理ディスク装置に分散 管理されたファイルの処理を行うファイルシステムにお いて、前記物理ディスク装置の少なくとも1つは、1つ のマウントポイントに対して物理ディスク装置にアクセ スするための1つ以上の10パスを対応づける情報を1 つのエントリに含むマウント構成ファイルを格納してお り、システム立ち上げ時、前記マウント構成ファイルを 格納するディスク装置が接続されたノードのファイルサ ーバは、前記マウント構成ファイルを読み出し、前記マ ウント構成ファイルの1つのエントリに記載された1つ 以上のIOパスに対して1つの論理ディスクIDを自動 設定し、前記論理ディスクIDと前記IOパスとの対応 関係を論理ディスク管理テーブルに登録し、他の全ての ノードのファイルサーバと通信を行うことによって、前 記論理ディスク管理テーブルの内容を全てのノードの論 理ディスク管理テーブルに複写し、前記マウント構成フ ァイルによって前記IOパスに対応づけられたマウント ポイントに前記論理ディスクIDに対応する論理ディス クをマウントし、複数のノードのそれぞれは、ファイル ID及び前記ファイルIDに対応するファイルが格納さ れている論理ディスクの論理ディスクIDを含むファイ ル管理テーブルと、論理ディスクID及び前記論理ディ スクに対応する1つ以上の物理ディスク装置にアクセス するための1つ以上のIOパスを含む論理ディスク管理 テーブルとを備え、ユーザからのファイルIDを指定し たファイルへのアクセス要求を受信したファイルサーバ は、ファイル管理テーブルを参照し、前記ファイルID から前記ファイルが格納されている論理ディスクの論理 ディスクIDを決定し、論理ディスク管理テーブルを参 照して前記論理ディスク I Dから前記論理ディスクに対 応する物理ディスク装置にアクセスするためのIOパス を決定し、決定したIOパスを使用して物理ディスク装 置にアクセスすることを特徴とするファイルシステム。

【請求項6】 前記マウント構成ファイルは、IOパス 毎に前記IOパスが使用できるか否かを登録する使用可 否情報を含み、論理ディスク管理テーブルは、前記論理 ディスク管理テーブルに登録されているIOパス毎に稼働状態を保持する状態フラグを含み、マウント処理を行うファイルサーバは、システム立ち上げ時に、前記マウント構成ファイルの1つのエントリに記載された複数の IOパスのうち、前記マウント構成ファイルの使用可 を登録されたIOパスの1つについて、論理ディスク管理テーブルの前記IOパスに対応する状態フラグに「使用中」状態と登録し、前記マウント

構成ファイルの使用可否情報に「使用可」と登録された 残りのIOパスについて、前記論理ディスク管理テープ ルの前記IOパスに対応する状態フラグに「待機中」状態と登録し、前記マウント構成ファイルの使用可否情報 に「使用不可」と登録されたIOパスについて、前記論 理ディスク管理テーブルの前記IOパスに対応する状態 フラグに「使用不可」状態と登録し、各ノードのファイルサーバは、通常運用時、前記論理ディスク管理テーブルの状態フラグが「使用中」状態となっている運用系の IOパスを用いて、物理ディスク装置にアクセスすることを特徴とする請求項5記載のファイルシステム。

【請求項7】 前記物理ディスク装置のディスクコント ローラ、前記物理ディスク装置が接続されたノードのI Oインターフェイスなどの障害によって、運用系IOパ スが使用不可能になったとき、前記障害を検出したノー ドのファイルサーバは、前記ノードの論理ディスク管理 テーブルを更新し、前記使用不可能になったIOパスの 状態フラグを「使用不可」とし、前記使用不可能になっ たIOパスと同じ論理ディスクIDに対応付けられてい るIOパスのうち状態フラグが「待機中」である1つの IOパスの状態フラグを「使用中」として新運用系IO パスとした後、全ての他のリモートノードのファイルサ ーバと通信を行い、前記論理ディスク管理テーブルの内 容を全ノードの論理ディスク管理テーブルに複写するこ とによって、前記物理ディスク装置へアクセスするため のIOパスを前記使用不可能となったIOパスから前記 新運用系IOパスに切り替えることを特徴とする請求項 6記載のファイルシステム。

【請求項8】 前記IOパスの切り替え処理の間、使用不可能となったIOパスに含まれるノードのファイルサーバは、使用不可能になったIOパスへのアクセス要求を保留し、IOパスの切り替え処理終了時、保留していた前記アクセス要求を新運用系IOパスに含まれるノードに転送することを特徴とする請求項7記載のファイルシステム。

【請求項9】 前記IOパスの切り替え処理の間、使用不可能となったIOパスに含まれるノードにアクセス要求を発行したファイルサーバは、前記アクセス要求がタイムアウトになった場合、論理ディスク管理テーブルを参照し論理ディスクIDからIOパスを求め直し、新しく求め直したIOパスを使用して、物理ディスク装置にアクセスし直すことを特徴とする請求項7記載のファイルシステム。

【請求項10】 前記複数のノードのそれぞれは、物理ディスク装置との間に転送されるデータを一時的に保持するバッファキャッシュを備え、IOパスの切り替え処理時、使用不可能になったIOパスに含まれるノードのファイルサーバとが通信を行い、前記使用不可能になったIOパスに含まれるノードの主記憶内に存在し、物

理ディスク装置に書き戻す必要があるバッファキャッシュ及びファイル管理テーブルを前記新運用系IOパスに含まれるノードに転送することを特徴とする請求項7記載のファイルシステム。

【請求項11】 前記物理ディスク装置内のディスクコントローラは、ディスク領域との間で転送されるデータを一時的に保持するディスクキャッシュを備え、前記物理ディスク装置内の別のディスクコントローラが備えるディスクキャッシュに格納されたデータをディスク時間になったIOパスを使ってアクセスに書き戻す機能を有し、IOパスを使ってアクセスに書き戻す機能を有し、IOパスを使ってアクセスに書き戻す機能を有して設けられた前記使用不可能になったIOパスを使ってアクセスに合まれるディスクコントローラを使用して、前記物理ディスク装置内に存在し、新運用系IOパスに含まれるディスクコントローラを使用して、前記物理ディスクまでは表記である。

【請求項12】 I Oパスの切り替え終了時、マウント構成ファイルを格納するディスク装置が接続されたノードのファイルサーバが前記マウント構成ファイルを更新し、前記使用不可能となった I Oパスの使用可否情報を「使用不可」に書き換えることを特徴とする請求項7記載のファイルシステム。

【請求項13】 使用不可能となっていたIOパスが再び使用できるようになったとき、前記複数のノードのある1つのノードのファイルサーバが、自ノードの論理ディスク管理テーブルに登録された前記IOパスの状態フラグを「使用不可」状態から「待機中」状態に更新し、前記ファイルサーバが他の全てのノードのファイルサーバと通信を行うことにより、全てのノードの論理デーブルに前記更新内容を複写した後、マウント構成ファイルを格納するディスク装置が接続されたノードのファイルサーバが、前記マウント構成ファイルに登録された前記IOパスの使用可否情報を「使用可」に書き換えることにより、前記IOパスを待機系IOパスとしてシステムに復旧させることを特徴とする請求項7記載のファイルシステム。

【請求項14】 物理ディスク装置が接続されたノードに障害が発生したとき、前記ノードの障害を検出した他のノードのファイルサーバは、自ノードの論理ディスク管理テーブルを検索し、障害発生ノード番号から障害発生IOパス及び前記障害発生IOパスと同じ論理ディスクIDに対応付けられているIOパスのうち状態フラグが「待機中」であるIOパスの1つを新運用系IOパスとして求め、この新運用系IOパスに含まれるノードのファイルサーバにIOパスの切り替え処理を行うように要求し、前記要求を受けた前記ファイルサーバは、自ノードの論理ディスク管理テーブルを更新し、前記障害発

生IOパスの状態フラグを「使用不可」とし、前記新運用系IOパスの状態フラグを「使用中」とした後、他の全てのノードのファイルサーバと通信を行い、前記論理ディスク管理テーブルの内容を全ノードの論理ディスク管理テーブルに複写することによって、前記物理ディスク装置へアクセスするためのIOパスを前記障害発生IOパスから前記新運用系IOパスに切り替えることを特徴とする請求項6記載のファイルシステム。

【請求項15】 I Oパスの切り替え処理の間、前記障害発生I Oパスに含まれるノードにアクセス要求を発行したファイルサーバは、前記アクセス要求がタイムアウトになった場合、論理ディスク管理テーブルを参照し論理ディスク I Dから I Oパスを求め直し、新しく求め直した I Oパスを使用して、物理ディスク装置にアクセスし直すことを特徴とする請求項14記載のファイルシステム。

【請求項16】 前記物理ディスク装置が接続されているノードは、自ノードの状態にかかわりなく自ノードが備えるメモリ内のデータを読み出し、読み出したデータを他のノードに転送する機能を持ったハードウェアを有し、IOパスの切り替え処理時、前記ハードウェアを用いて、前記障害発生IOパスに含まれるノードの主記憶内に存在し、物理ディスク装置に書き戻す必要があるバッファキャッシュ及びファイル管理テーブルを前記新運用系IOパスに含まれるノードに転送することを特徴とする請求項14記載のファイルシステム。

【請求項17】 前記物理ディスク装置内のディスクコントローラは、ディスク領域との間で転送されるデータを一時的に保持するディスクキャッシュを備え、前記物理ディスク装置内の別のディスクコントローラが備えるディスクキャッシュに格納されたデータをディスク領域に書き戻す機能を有し、IOパスの切り替え処理時、前記障害発生IOパスを使ってアクセスしていた物理ディスク装置内に設けられた前記障害発生IOパスに含まれるディスクコントローラが備えるディスクキャッシュに格納されたデータのうち、前記物理ディスク装置に書き戻す必要のあるデータを、前記物理ディスク装置に書き存在し、新運用系IOパスに含まれるディスクコントローラを使用して、前記物理ディスク装置に書き戻すことを特徴とする請求項14記載のファイルシステム。

【請求項18】 I Oパスの切り替え終了時、マウント構成ファイルを格納するディスク装置が接続されたノードのファイルサーバが前記マウント構成ファイルを更新し、使用できなくなった運用系 I Oパスの使用可否情報を「使用不可」に書き換えることを特徴とする請求項14記載のファイルシステム。

【請求項19】 前記マウント構成ファイルは、IOパス年に前記IOパスが使用できるか否かを登録する使用可否情報を含み、前記論理ディスク管理テーブルは、該論理ディスク管理テーブルに登録されているIOパス毎

に稼働状態を保持する状態フラグを含み、前記マウント処理を行うファイルサーバは、システム立ち上げ時に、前記マウント構成ファイルの使用可否情報に「使用可」と登録されたIOパスについて、論理ディスク管理テーブルの前記IOパスに対応する状態フラグに「使用不可」と登録されたIOパスについて、論理ディスク管理テーブルの前記IOパスに対応する状態フラグに「使用不可」と登録されたIOパスに対応する状態フラグに「使用不可」状態と登録し、通常運用時、ファイルサーバは、前記論理ディスク管理テーブルの状態フラグに「使用中」状態のIOパスからアクセスされる物理ディスク装置にファイルをミラーリングすることを特徴とする請求項5記載のファイルシステム。

【請求項20】 前記使用中IOパスの1つに障害が発生したとき、この障害を検出したノードのファイルサーバは、自ノードの論理ディスク管理テーブルを更新し、障害が発生した前記IOパスの状態フラグを「使用不可」とした後、他の全てのノードのファイルサーバと通信を行い、前記論理ディスク管理テーブルの内容を全ノードの論理ディスク管理テーブルに複写し、マウント構成ファイルを格納するディスク装置が接続されたノードのファイルサーバが、前記マウント構成ファイルを更新し、前記障害が発生したIOパスの使用可否情報を「使用不可」に書き換えることによって、障害が発生したIOパスを切り放すことを特徴とする請求項19記載のファイルシステム。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、複数のディスク装置に分散管理されたファイルの処理を行うファイルシステムに係り、特に、1つのディスク装置へアクセスするためのIOパスが複数存在する場合に、IOパスの切り替えを制御を行って一方のパスからディスク装置へアクセスすることができるファイルシステムに関する。

[0002]

【従来の技術】従来技術によるファイルシステムの1つであるUNIX(登録商標)ファイルシステムは、各ファイル毎にユニークに決まる番号(ファイルID)が定義されており、ファイルサーバがファイルIDを指定することによって、リード・ライト処理を行うファイルを特定することができる。そして、ファイルサーバは、ファイルIDとそのファイルが格納されているディスク装置にアクセスするためのIOパス(IOパスを決定する情報は、ノード番号、IOインターフェイス番号、装置番号などである)との対応関係をメモリ上のファイル管理テーブル(UNIXではinodeと呼ばれる)に登録して管理している。この管理方法については、例えば、(The Design of The Unix Operating System; Maurice J. Bach: p60-p72)に述べられている。

【0003】ファイルIDを指定したリード・ライトア

クセス要求に対して、ファイルサーバは、前述のファイル管理テーブルを参照し、ファイルIDからディスク装置にアクセスするためのIOパス名を決定し、そのIOパスを用いてディスク装置にアクセスを行う。ファイル管理テーブルには、IOパス情報の他に、ファイルサイズやファイルの更新日付などのファイル管理情報が登録されており、このファイル管理情報は、ファイルがオープンされたとき、ディスク装置から読み出され、定期的あるいはファイルをクローズしたときに、ディスク装置に書き戻される。ユーザがファイルにアクセスするとき指定するファイル名からファイルIDへの変換は、ファイルサーバが行っている。

【0004】また、複数のディスク装置をシステムで取 り扱う場合、あるディスク装置Aで管理されるディレク トリネームツリー内のいずれかのディレクトリ、例え ば、Xに別のディスク装置Bで管理されるネームツリー を組み込むという操作によって、複数のディスク装置を 1つのネームツリー内に見せるという方法が知られてい る。この方法によれば、ユーザは、ディレクトリXにア クセスすればディスク装置B内のファイルにアクセスす ることができる。この方法は、マウント処理と呼ばれて いるものである。ファイルサーバは、起動時にある特定 のディスク装置(ルートデバイス)を起点として前述し たマウント処理を次々に行い、ユーザには複数のディス ク装置を1つのネームツリーとして見せるようにしてい る。この起動時におけるマウント処理を行うためのディ スク装置とネームツリー上のディレクトリ名(マウント ポイント)との対応関係を記述した情報は、ルートデバ イスにマウント構成ファイルとして記録されており、フ ァイルサーバは、起動時にこのマウント構成ファイルに 記載された情報に従ってマウント処理を行う。

【0005】マウント構成ファイルには、ディスク装置を特定する情報として、そのディスク装置にアクセスするためのIOパスの情報が記載されている。ファイルサーバは、マウント処理の実行時に、マウント構成ファイルに記載されたIOパスとマウントポイントとの対応関係をメモリ上のマウント構成情報に読み込む。そしてファイルサーバは、ユーザがファイル名を指定してファイルをオープンするとき、前述のマウント構成情報を元にファイルが格納されている物理ディスク装置にアクセスするためのIOパスを求め、ファイル管理テーブルを作成する。従って、システム管理者は、システムに新しいディスク装置を接続するなどしてシステムの構成を変更したとき、マウント構成ファイルを書き換えることによって、新しい構成情報を計算機システムに設定する必要がある。

【0006】一方、計算機システムの信頼性を向上させるため、異なる2つのノードを1つのディスク装置に物理的に接続し、異なる2通りのIOパスからディスク装置にアクセスすることができる構成にしておき、通常の

運用時に一方のIOパスを使用し、ノード障害が発生して使用中のIOパスが使用できなくなったとき、もう一方のIOパスを用いて別のノードからディスク装置にアクセスするようにすることによって、障害発生時においてもディスク装置の可用性(アベイラビリティ)を保つ方法が、例えば、特開平10-275090号公報等に記載されて知られている。

【0007】また、ディスク装置の信頼性を向上するために、ファイルを複数のディスクに多重化して記録する方法(ミラーリング)がよく知られている。ミラーリングを行う場合、一般に、論理ボリュームという概念が用いられる。ミラーリングは、複数の物理ディスク装置を、1つの論理ボリュームとしてユーザに見せる仕組みである。ユーザは、予め複数の物理ディスク装置の情報を登録した「論理ボリューム」を作成して、物理ディスク装置と同様にアクセスすると、複数の物理ディスへのファイルのミラーリングが行われる。論理ボリュームを使用することにより、ファイルを複数のディスク装置に分散記録するストライピングを行うことも可能となる。

[0008]

【発明が解決しようとする課題】前述で説明した使用中のIOパスが使用不可能になったとき、物理ディスク装置にアクセスするためのIOパスを別のIOパスに切り替える処理を、従来のUNIXのファイルシステムに切用して動的に行おうとすると、ファイル管理テーブル及びマウント構成情報を検索し、使用できなくなったIOパス名を新しいIOパス名に書き換える操作を行う必要がある。前述のファイル管理テーブルのエントリを書き換える処理は、オープンされているファイルの個数だけ全てについて行わなければならない。この結果、従来のUNIXのファイルシステムに、前述したIOパスの切り替えの技術を適用した場合、ファイル管理テーブルのり替えの技術を適用した場合、ファイル管理テーブルのカリを書き換える処理に時間がかかり、その間その物理ディスク装置にIO処理を行うことができないという問題点を生じることになる。

【0009】また、IOパスに障害が発生したときに、単純にIOパスを切り替えるだけでは、障害発生前に物理ディスク装置にアクセスを行っていたノードが持っていたバッファキャッシュ(物理ディスク装置にリード・ライトするときにデータを一時的に蓄えておき、メメカリに比べて処理速度の遅い物理ディスク装置への入出カ回数を削減するためのメモリ領域)やファイル管理テーブル、及び、ディスク装置上のディスクキャッシュ(バッファキャッシュと同様の目的のために物理ディスク装置が備えるキャッシュメモリ)の内容が正常に物理ディスク装置に書き戻されず、大切なデータが消えてしまうという問題点をも生じる。しかも、これが原因でファイルシステムの整合性が異常となるため、物理ディスク装置

に冗長に記録されたファイルシステムの情報を元にファイルシステムの整合性を正常状態に戻す操作が必要となる。この操作は、ディスク装置全体をチェックする必要があるため、長い時間を要する。この結果、この間、その物理ディスク装置に対する I O処理を行うことはできないという問題点を生じさせてしまう。

【0010】さらに、IOパス切り替え後、新しいIOパスを用いてディスク装置にアクセスを行うので、IOパス切り替え後にシステムを再起動したときにマウント処理が正常に行われるようにするには、システム管理者がマウント構成ファイルを更新し、ディスク装置への新しいIOパスとマウントポイントとの対応関係をマウント構成ファイルに登録しなおす必要がある。また、ファイルのミラーリングを行う場合、論理ボリュームを作成する必要があるが、論理ボリュームの管理は、システム管理者に対して煩雑な作業を行わせることになる。

【0011】本発明の第1の目的は、IOパスの切り替 え処理のために要する時間を短縮し、一般ユーザから I Oパス切り替え処理をできるだけ隠蔽することができる ファイルシステムを提供することにある。また、本発明 の第2の目的は、IOパスの切り替え時に、バッファキ ャッシュやファイル管理テーブル及びディスク装置上の ディスクキャッシュに保存されたデータを失うことなく IOパスの切り替え処理を行い、ファイルの整合性のチ ェックを不要とすることができるファイルシステムを提 供することにある。また、本発明の第3の目的は、IO パスを切り替えたとき自動的にマウント構成ファイルを 更新し、システム管理者の負担を軽減することのできる ファイルシステムを提供することある。さらに、本発明 の第4の目的は、ユーザに論理ボリュームを意識させず にファイルのミラーリングを行う方法を備えたファイル システムを提供することにある。

[0012]

【課題を解決するための手段】本発明によれば前記目的 は、ファイル毎にファイルIDが定義されており、複数 の物理ディスク装置に分散管理されたファイルの処理を 行う1または複数のファイルサーバを有するファイルシ ステムにおいて、ファイルID及び該ファイルIDに対 応するファイルが格納されている論理ディスクの論理デ ィスクIDを含むファイル管理テーブルと、論理ディス クID及び前記論理ディスクに対応する1つ以上の物理 ディスク装置にアクセスするための1つ以上の10パス を含む論理ディスク管理テーブルとを備え、ユーザから のファイルIDを指定したファイルへのアクセス要求を 受信したファイルサーバは、ファイル管理テーブルを参 照し、前記ファイルIDから前記ファイルが格納されて いる論理ディスクの論理ディスクIDを決定し、論理デ ィスク管理テーブルを参照して前記論理ディスクIDか ら前記論理ディスクに対応する物理ディスク装置にアク セスするためのIOパス(IOパスを決定する情報は、

ノード番号、IOインターフェイス番号、ディスクコントローラ番号である)を決定し、決定したIOパスを使用して物理ディスク装置にアクセスすることにより達成される。

【0013】前述において、論理ディスク管理テーブルは、該論理ディスク管理テーブルに登録されているIOパス毎に稼働状態(「使用中」、「待機中」、「使用不可」)を保持する状態フラグを含み、通常運用時、ファイルサーバは状態フラグが「使用中」状態のIOパス(運用系IOパス)を用いて物理ディスク装置にアクセスする。前記運用系IOパスの障害発生時、障害を検出したノードのファイルサーバは、前記ノードの論理ディスク管理テーブルを更新し、が能フラグが「待機中」状態であるIOパスの状態フラグを「使用中」とし、状態フラグが「待機中」状態であるIOパスとした後、全リモートノードのファイルサーバと通信を行い、前記論理ディスク管理テーブルの内容を全ノードの論理ディスク管理テーブルに複写することによって、前記物理ディスク装置にアクセスするた

【0014】このIOパス切り替え処理の間、前記障害発生IOパスに含まれるノードのファイルサーバは、旧運用系IOパスへのアクセス要求を保留し、IOパス切り替え処理終了時、保留していたアクセス要求を前記新運用系IOパスが含むノードに送信する。これによって、IOパス切り替え処理を動的に行うことが可能となり、IOパス切り替え時ファイル管理テーブルを検索・更新する必要をなくし、IOパス切り替え処理に要する時間を短縮することができる。

めのIOパスを旧運用系IOパスから新運用系IOパス

に切り替える。

【0015】また、前述において、IOパスの切り替え 処理時、使用できなくなった旧運用系IOパスを使って アクセスしていた物理ディスク装置内に設けられたディ スクコントローラが有するディスクキャッシュに格納さ れたデータのうち、前記物理ディスク装置に書き戻す必 要のあるデータを、前記物理ディスク装置内に設けられ た別のディスクコントローラを使用して前記物理ディス ク装置に書き戻し、前記旧運用系IOパスに含まれるノ ードのファイルサーバと新運用系IOパスに含まれるノ ードのファイルサーバが通信を行うことによって、前記 旧運用系IOパスに含まれるノードの主記憶内に存在 し、前記物理ディスク装置に書き戻す必要があるバッフ ァキャッシュ及びファイル管理テーブルを前記新運用系 IOパスに含まれるノードに転送する。本発明は、これ によって、ディスク装置上のディスクキャッシュに存在 していたデータや、バッファキャッシュや、ファイル管 理テーブルが消失するのを防ぎ、ファイルシステムの整 合性のチェックを不要とすることができる。

【0016】また、前述において、マウント構成ファイルは、IOパス毎にそのIOパスが使用できるか否かを

登録する使用可否情報を含み、ファイルサーバは、シス テム起動時に前記マウント構成ファイルを読み込み、前 記使用可否情報に「使用可」と記載されたIOパスにつ いて、対応する論理ディスク管理テーブルの状態フラグ を「使用中」または「待機中」と登録し、前記使用可否 情報に「使用不可」と記載されたIOパスについて、対 応する論理ディスク管理テーブルの状態フラグを「使用 不可」と登録することにより、マウント構成ファイルに 「使用可」と記載されたIOパスだけを使用して物理デ ィスク装置にアクセスをする設定を行っている。IOパ ス切り替え・切り離し処理終了後、ファイルサーバは、 前記マウント構成ファイルを更新し、使用できなくなっ た旧運用系IOパスの使用可否情報を「使用不可」に書 き換える。また、使用不可能となったIOパスが再び使 用できるようになったとき、ファイルサーバは、マウン ト構成ファイルを更新し、使用可能になった前記IOパ スの使用可否情報を「使用可」に書き換える。このよう に、本発明は、IOパスが切り替わったときや復旧した ときのマウント構成ファイルの書き換え処理を自動化す ることにより、システム管理者の負担を軽減することが できる。

【0017】また、本発明は、マウント構成ファイルの1つのエントリに書かれた複数のIOパスからアクセスされる複数のディスク装置に対して、ファイルのミラーリングを行うことができ、これにより、ユーザが論理ボリュームを使用することなくファイルのミラーリングを行うことができる。

[0018]

【発明の実施の形態】以下、本発明によるファイルシステムの実施形態を図面により詳細に説明する。

【0019】図1は本発明の第1の実施形態によるファイルシステムの構成を示すプロック図、図2はシステム内に設けられる各種のテーブルの具対的な構成例を説明する図、図3はマウント構成ファイルの具体的な構成例を説明する図である。図1~図3において、1はネットワーク、10、20、30は物理ディスク装置、11、12、21、22はディスクコントローラ、24はマウント構成ファイル、100、200、300はノード、110、210、310はCPU、120、220、320はメモリ、130、230はユーザアプリケーション(UAP)、140、240はファイルサーバ(FS)、250はディスクドライバ、160、260はファイル管理テーブル、170、270は論理ディスク管理テーブル、180、280はバッファキャッシュ、290、390は10インタフェースである。

【0020】本発明の第1の実施形態によるファイルシステムは、図1に示すように、超並列計算機システムを構成するノード100、200、300(図1では3つのノードのみを示しているが、ノードは多数設けられる)がネットワーク1によって相互に接続されて構成さ

れている。ノード200とノード300とには、両ノードからアクセス可能な共用物理ディスク装置10、20が接続されている。物理ディスク装置10、20は、それらのディスク装置内に設けられたディスクコントローラ11、12及びノード200内に設けられたIOインターフェイス290によってノード200と接続されると共に、ディスクコントローラ12、22及びノード300内に設けられたIOインターフェイス390によってノード300と接続されている。ノード100に接続されている物理ディスク装置30は、物理ディスク装置10、20と比べて障害発生率が極めて低い高信頼ディスク装置である。

【0021】ノード200は、CPU210とメモリ220とから構成される。メモリ220は、ユーザアプリケーション230と、ファイル制御を行うファイルサーバ240と、ディスクIO処理を行うディスクドライバ250と、ファイル管理テーブル260と、論理ディスクを定義している論理ディスク管理テーブル270と、バッファキャッシュ280とを含む。ノード100及びノード300は、ノード200と同様に構成されている。

【0022】物理ディスク装置にアクセスするための入出力経路をIOパスと呼び、このIOパスは、ノード番号、IOインターフェイス番号、ディスクコントローラ番号の3つの情報で決定され、IOパスを決めると物理ディスク装置を一意に決めることができる。例えば、

(ノード番号、IOインターフェイス番号、コントローラ番号) = (200, 290, 11) というIOパスからは、物理ディスク装置10にアクセスされる。以後の説明において、IOパスは、前述のような形式で記載することとする。

【0023】論理ディスクは、1つ以上の物理ディスク 装置を組み合わせたものとして構成される。その物理デ ィスクの組み合わせは、IOパスを指定することによっ て行われる。例えば、(200, 290, 11)、(3 00,390,22)という2つのIOパスを組み合わ せると、物理ディスク装置10、20を纏めた論理ディ スクを構成することができる。その際、物理ディスク装 置10、20に同一の内容を記録するようにすれば、論 理ディスクをミラー化することができる。また、(20 0, 290, 11)、(300, 390, 12)という 2つの I Oパスを組み合わせると、これらの I Oパスか らは共に物理ディスク装置10にアクセスされるため、 物理ディスク装置10に対応する論理ディスクが構成さ れる。但し、この場合、物理ディスク装置10にアクセ スするためのIOパスが2通り存在するので、片方のI Oパスに障害が発生した場合でも、別のIOパスから物 理ディスク装置10にアクセスすることができ、これに よって、ディスク装置の信頼性の向上を図ることができ る。説明する本発明の第1の実施形態は、論理ディスク

が1つの物理ディスク装置に対応する後者の場合を例と して取り扱う。

【0024】論理ディスク管理テーブル270は、図2(b)に示すように、論理ディスクID271と、ノード番号272、276と、IOインターフェイス番号273、277と、ディスクコントローラ番号274、278と、状態フラグ275、279とから構成される。272~274は、論理ディスクID271に対応する物理ディスク装置にアクセスするための第1のIOパスを決定し、状態フラグ275には、このIOパスの稼働状態(「使用中」、「待機中」、「使用不可」のいずれか)が登録される。276~278は、物理ディスク装置にアクセスするための第2のIOパスを決定し、このIOパスの稼働状態が状態フラグ279に登録される。このように論理ディスク管理テーブル270には、1つの論理ディスクIDに対して2通りのIOパスとそれぞれのIOパスの状態フラグを登録できるようになっている。

【0025】本発明の第1の実施形態において、前述の2つのIOパスからアクセスされる物理ディスク装置は同一のものであり、通常運用時は2つのIOパスのうち1つを使用し(状態フラグが「使用中」状態になっている)、もう一方のIOパスを「待機中」状態としておき、ディスクコントローラやIOパスが使用できなくなったとき、ファイルサーバが物理ディスク装置にアクセスするためのIOパスを「待機中」状態のIOパスに切り替える。このように、論理ディスク管理テーブルは、論理ディスクIDと物理ディスク装置にアクセスするためのIOパスとを対応付けることによって、仮想的なディスク装置として論理ディスクを定義している。論理ディスクIDはこの論理ディスクを識別するための番号である。

【0026】また、システムを構成する各ノードが持つ 論理ディスク管理テーブルの内容は常に同一となっている。例えば、図1において、ノード100が持つ論理ディスク管理テーブル170と、ノード200が持つ論理ディスク管理テーブル270と、ノード300が持つ論理ディスク管理テーブル370は常に同一の内容を有する。

【0027】ファイル管理テーブル260は、図2 (a) に示すように、ファイルID261と論理ディスクID262とファイル管理情報263とにより構成される。ファイルID261には、現在オープンされているファイルのファイルIDが登録され、論理ディスクID262には、前述のファイルが格納されている論理ディスクの論理ディスクIDが登録される。ファイル管理情報263には、前述のファイルのファイルサイズや更新日付等の情報が登録される。このファイル管理テーブル260の各エントリは、ノード200上で動作するプ

ログラムがファイルをオープンする度に、物理ディスク 装置上から各ファイル固有の情報として読み出される。 従って、ファイル管理テーブル260のエントリは、少なくともオープンされているファイルの個数分存在する。

【0028】バッファキャッシュ280は、物理ディスク装置にアクセスを行うときにリード・ライトするデータを一時的に蓄えておき、メモリに比べて処理速度の遅い物理ディスク装置への入出力処理回数を削減するために使用される。バッファキャッシュ280は、図2(c)に示すように、論理ディスクID281とブロック番号282とキャッシュデータ283には、論理ディスクID281のブロック番号282で指定されるディスク領域の

データの内容が格納される。

【0029】高信頼な物理ディスク装置30内には、マ ウント構成ファイル24が格納されている。マウント構 成ファイル24のエントリは、図3に示すように、シス テムに接続される物理ディスク装置にアクセスするため のIOパス名51、53と、そのIOパスが使用可能か 否かを示す使用可否情報52、54と、前述の物理ディ スク装置に対応する論理ディスクをマウントするマウン トポイント55との3つの情報を含んでいる。マウント 構成ファイル24には、IOパス名が"(ノード番号, IOインターフェイス番号,ディスクコントローラ番 号) = (200, 290, 11) "のような形式で記述 され、そのIOパスが使用可能な場合、マウント構成フ ァイル24の対応するIOパスの使用可否情報に"avai lable" と記述され、そのIOパスが使用不可能な場 合、使用可否情報に"unavailable"と記述される。図 3に示した例では、IOパス(200, 290, 11) と (300, 390, 12) との両者がマウントポイン ト /mntに対応付けされており、共に使用可能となって いる。この記述によって、ユーザが /mntディレクトリ 以下のディレクトリツリー内のファイルにアクセスした とき、物理ディスク装置10にアクセスできるようにな る。このとき、物理ディスク装置10にアクセスするため めのIOパスは、前述のいずれかのIOパスが使用され る。使用していない方のIOパスは「待機中」状態とし てスタンバイしている。

【0030】前述のように、物理ディスク装置にアクセスするためのIOパスが2つ存在する場合、その2つのIOパスを同じエントリに記載することにより、2つのIOパスを1つのマウントポイントに対応付けることができる。マウント構成ファイル24は、通常のエディタなどで編集することが可能であり、システム管理者は、システムの構成を変更したとき、マウント構成ファイル24の内容が新しいシステム構成と一致するように、マウント構成ファイル24を編集し、システムをリプートさせる。システムの起動時、ファイルサーバ140は、

修正後のマウント構成ファイル24に従ってマウント処理を行うので、リプート後、新しいシステム構成が使用可能となる。例えば、図1に示した物理ディスク装置装置20をシステムに追加したとき、システム管理者は"((200,290,21) available)((300,390,22) available) /mnt1"という行をマウント構成ファイル24に追加してシステムをリプートする。この記述によって、ユーザが /mnt1 ディレクトリにアクセスしたとき、前述の追加行に記載したいずれかのIOパスから物理ディスク装置20にアクセスできるようになる。

【0031】図4はシステムの起動時のファイルサーバの処理動作を説明するフローチャート、図5はシステム全体のノードの論理ディスク管理テーブルを更新する処理動作を説明するフローチャートであり、次に、これらのフローを参照して、システムの起動時にファイルサーバ140がマウント構成ファイル24を読み込み、論理ディスク管理テーブルを設定してマウント処理を行うまでの処理手順及び全ノードでの論理ディスク管理テーブルの更新の処理手順を説明する。

【0032】(1)システムの起動時、ノード100内のファイルサーバ140は、高信頼ディスク装置30上に格納されているマウント構成ファイル24の1つのエントリを読み込む(ステップ401、402)。

【0033】(2)ファイルサーバ140は、マウント構成ファイル24に記載された I Oパス名に対して論理ディスク I Dを自動的に設定する。マウント構成ファイル2401 つのエントリに複数の I Oパス名が記載されていた場合、ファイルサーバ140 は、その複数の I Oパスに対して1 つの論理ディスク I Dを設定する。例えば、図3 に示した例の場合、ファイルサーバ140 は、I Oパス名51 "(200, 290, 11)"及びI Oパス名53 "(300, 390, 12)"に対して論理ディスク I D "123"を設定する。ファイルサーバ140 は、これにより、設定した論理ディスク I D を論理ディスク管理テーブル170 の論理ディスク I D 171 に登録する(ステップ170 の。

【0034】(3)前述の第1のIOパス名をノード番号172、IOインターフェイス番号173、ディスクコントローラ番号174に登録し、第2のIOパス名をノード番号176、IOインターフェイス番号177、ディスクコントローラ番号178に登録する。図3に示した例の場合、論理ディスクID171には"123"、ノード番号172には"200"、IOインターフェイス番号173には"290"、ディスクコントローラ番号174には"11"、ノード番号176には"300"、IOインターフェイス番号177には"390"、ディスクコントローラ番号178には"12"が登録される(ステップ404)。

【0035】(4) そして、ファイルサーバ140は、

マウント構成ファイル 2 4 の使用可否情報に "availab le" と記載されている最初の I Oパス "(200,390,11)"について、論理ディスク管理テーブル 1 7 0 の対応する状態フラグを「使用中」状態と登録し、"available" と記載されている残りの I Oパス "(300,390,12)"について、対応する状態フラグを「待機中」状態と登録する。また、ファイルサーバ 1 4 0 は、マウント構成ファイル 2 4 の使用可否情報に、"unavailable" と記載されている I Oパスについては対応する状態フラグを「使用不可」状態と登録する。この結果、論理ディスク管理テーブル 1 7 0 の内容は、図

【0036】(5)ファイルサーバ140は、マウント 構成ファイル24に記載された全てのエントリについ て、論理ディスク管理テーブル170への登録が終了し たか否かをチェックし、終了していない場合、ステップ 402からの処理を繰り返し実行して論理ディスク管理 テーブルへの登録を続ける(ステップ406)。

2に示したようなものとなる(ステップ405)。

【0037】(6)ステップ406で、マウント構成ファイル24に記載された全てのエントリについて、論理ディスク管理テーブル170への登録が終了していた場合、ファイルサーバ140は、全ての他のノード200、300であるリモートノードのファイルサーバと通信を行い、システムを構成する全ノードの論理ディスク管理テーブルの更新を行わせる(ステップ407)。

【0038】(7)ファイルサーバ140は、全リモートノードから論理ディスク管理テーブルの更新完了の通知を受信したら、マウント構成ファイル24に記載されているIOパス名("(200,290,11)"及び"(300,390,12)")とマウントポイント/mntとの対応関係、及び、論理ディスク管理テーブル170に登録した上記IOパス名と論理ディスクID"123"との対応関係から、マウントポイント/mntと上記論理ディスクID"123"との対応関係を作り、論理ディスクID"123"に対応する論理ディスクをマウントポイント/mntにマウントする(ステップ408)。

【0039】次に、図5に示すフローを参照して前述したステップ407の処理時のファイルサーバ140及びリモートノードのファイルサーバの処理動作を説明する。

【0040】(1)ファイルサーバ140は、自ノード100の論理ディスク管理テーブルの設定を終了した後、全リモートノードのファイルサーバに論理ディスク管理テーブル140の内容を送信し、論理ディスク管理テーブルを更新するように要求する(ステップ901、902)。

【0041】(2)この通知を受けたリモートノードのファイルサーバは、送信されてきた論理ディスク管理テーブル170の内容を、そのノードの論理ディスク管理

テーブルに複写して論理ディスク管理テーブルの更新を行い、ファイルサーバ140に論理ディスク管理テーブルの更新終了を通知する(ステップ905~907)。【0042】(3)ファイルサーバ140は、全リモートノードからそれぞれのノードの論理ディスク管理テーブルの更新完了通知を受信するのを待ち、図4により説明したステップ408のマウント処理を実行して処理を終了する(ステップ903、904)。

【0043】図6は通常運用時のファイルサーバの処理動作を説明するフローチャートであり、次に、このフローを参照して、通常運用時のファイルアクセスの手順について説明する。ここでは、ファイル管理テーブル160、260及び論理ディスク管理テーブル170、270の設定が図2に示すようになっているとして、ローカルノードとしてのノード200に接続された物理ディスク装置にアクセスする場合について、ノード200上で動作するユーザアプリケーション230が、ファイルID"100"を指定したファイルアクセス要求をファイルサーバ240に発行した場合を例に説明する。

【0044】(1)ファイルサーバ240は、ユーザアプリケーション230からの要求を受信すると、この要求が他のノードであるリモートノードからの要求であるか否かを判定する(ステップ501、502)。

【0045】(2)説明している例では、自ノードであるローカルノードのユーザアプリケーションからのアクセスであるとしているので、ファイルサーバ240は、ファイル管理テーブル260を検索し、ファイルID"100"からそのファイルIDで定義されるファイルが格納されている論理ディスクの論理ディスクID"123"を求める(ステップ503)。

【0046】 (3) そして、ファイルサーバ 240は、 論理ディスク管理テーブル 270 を検索し、論理ディスク I Dから状態フラグが「使用中」状態の I Oパス名 "(200, 290, 11)"を求め、その I Oパス名 に含まれるノード番号"200"がローカルノードであるか否かを判定する(ステップ 504、505)。

【0047】(4)前述のIOパス名に含まれるノード番号"200"がローカルノードであるとして説明しているので、ステップ505で、前述のIOパス名に含まれるノード番号"200"がローカルノードであると判定され、ファイルサーバ240は、自ローカルノードのディスクドライバ250にIOパスを指定したIOアクセス要求を送る。この要求を受けたディスクドライバ250は、IOインターフェイス290を介してディスクコントローラ11に制御信号を送る(ステップ507)。

【0048】次に、他のノードであるリモートノードに接続された物理ディスク装置にアクセスする場合について説明する。ここで説明する例は、ノード100上で動作するユーザアプリケーション130が、ファイルID

"100"を指定したファイルアクセス要求をファイル サーバ140に発行した場合であるとする。

【0049】(1) ファイルサーバ140は、ユーザアプリケーション130からの要求を受信すると、ローカルノードに接続された物理ディスク装置にアクセスする場合と同様に、ファイル管理テーブルを160を検索しファイル ID "100" から論理ディスク ID "123" を求め、論理ディスク管理テーブル170を検索して論理ディスク ID "123" から IOパス名 "(200, 290, 11)" を求める(ステップ501~504)。

【0050】 (2) ファイルサーバ140は、上記 IO パス名に含まれるノード番号 "200" がリモートノードであることを確認すると、そのノード(ノード200) のファイルサーバ240に上記論理ディスク I Dを指定した I Oアクセス要求を送る(ステップ505、506)。

【0051】(3) この要求を受けたファイルサーバ240は、論理ディスク管理テーブル270を検索し論理ディスクID"123"から状態フラグが「使用中」状態のIOパス名"(200, 290, 11)"を求める(ステップ501、502、504)。

【0052】(4)ファイルサーバ240は、IOパスに含まれるノード番号"200"が自ノードであるローカルノードであることを確認して、ディスクドライバ250にIOパスを指定したIOアクセス要求を送る。この要求を受けたディスクドライバ250は、IOインターフェイス290を介してディスクコントローラ11に制御信号を送る(ステップ505、507)。

【0053】前述した処理動作の説明から判るように、ファイルサーバが自ノードであるローカルノードからアクセス要求を受ける場合、その要求は、全てユーザアプリケーションからの要求であり、他のノードであるリモートノードからの要求を受ける場合、その要求は、全てリモートノードのファイルサーバからの要求である。

【0054】実際のファイルアクセス処理は、バッファキャッシュを経由して行われる。ファイルサーバ240は、論理ディスクIDを指定したIOアクセス要求に対する処理を、バッファキャッシュ280に対するリード・ライト処理と、バッファキャッシュ280と物理ディスク装置10との間でのリード・ライト処理とに分けて行う。ファイルサーバ240は、バッファキャッシュ280と物理ディスク装置10との間のリード・ライトので動作するプログラクセス処理との実行時に、論理ディスクIDからIOパス名への変換を行う。ノード100で動作するプログラムが、リモートノードに接続された物理ディスクを置10にアクセスする場合、ノード100上のバッファキャッシュ180とノード200上のバッファキャッシュ180とノード200上のバッファキャッシト処理を行う場合のデータの流れは、バッファキャッシ

ュ180→バッファキャッシュ280→物理ディスク装置10となる。リード処理の場合、この逆の順序となる。

【0055】ユーザアプリケーションがファイルを更新し、ファイルの更新日付が変わるなどして、ファイル管理テーブルの内容が変更されたとき、ファイル管理テーブルの変更を物理ディスク装置に書き戻す必要がある。 次に、この書き戻し処理について説明する。

【0056】ファイル管理テーブルの内容が変更され、 その内容をローカルノードに接続された物理ディスク装 置に書き戻す場合、ローカルノードのファイルサーバが ローカルノードのファイル管理テーブルの内容を直接そ の物理ディスク装置に書き戻す。また、リモートノード に接続された物理ディスク装置に書き戻す場合、ローカ ルノードのファイルサーバは、物理ディスク装置が接続 されたノードにローカルノードのファイル管理テーブル の内容を一旦転送する。その後、物理ディスク装置が接 続されたノードのファイルサーバが物理ディスク装置に その内容を書き戻す。例えば、ノード100のファイル サーバ140がファイル管理テーブル160の内容を物 理ディスク装置10に書き戻す場合、まず、ファイルサ ーバ140は、物理ディスク装置への書き戻し処理を行 いたいファイル管理テーブル160のエントリ中の、論 理ディスク I D 1 6 2 ("1 2 3") を参照して、書き 戻す先の論理ディスクIDを求める。そして、論理ディ スク管理テーブル170を検索して上記論理ディスクI Dに対応する物理ディスク装置にアクセスするための I 〇パス("200, 290, 11")を求め、そのIO パス名に含まれるノード番号 ("200") に対応する ノード(ノード200)のファイルサーバ240に書き 戻しを行いたいファイル管理テーブルのエントリを送信 する。ファイルサーバ240は、受信したデータを一旦 ファイル管理テーブル260に書き込む。その後、ファ イルサーバ240は、ファイル管理テープルに保存され ている他のデータと纏めて、ファイル管理テーブル26 0の更新内容を物理ディスク装置10に書き込む。ファ イルサーバ240が物理ディスク装置10にアクセスす るための I Oパスは、論理ディスク管理テーブル270 を検索し、論理ディスクID262をIOパス名に変換 することによって求められる。

【0057】前述したように、最終的な物理ディスク装置へのデータの書き戻しは、物理ディスク装置が接続されたノードに存在するファイル管理テーブル及びバッファキャッシュから行っており、物理ディスク装置が接続されたノードのファイル管理テーブル及びバッファキャッシュには、ローカルノードのユーザアプリケーションに関係するもの以外にリモートノードのユーザアプリケーションに関係するものが存在する。

【0058】図7はIOパスの切り替えの処理動作を説明するフローチャート、図8~図10はIOパスに障害

が発生しI Oパスの切り替えを行う処理について説明する図である。図8~図1 0 において、1 3 はディスクキャッシュ、3 4 0 はファイルサーバ、3 5 0 はディスクドライバ、3 6 0 はバッファキャッシュであり、他の符号は図1 の場合と同一である。以下、これらの図を参照して、ディスクコントローラ1 1 で障害が発生し、通常使用しているI Oパス"(2 0 0, 2 9 0, 1 1)"が使用不可能になったとき、物理ディスク装置1 0 にアクセスするためのI Oパスを"(2 0 0, 2 9 0, 1 1)"から"(3 0 0, 3 9 0, 1 2)"に切り替える処理について説明する。

【0059】図9において、ディスクキャッシュ13は、ディスク装置10が備えるディスクコントローラ11の内部に設けられたディスクキャッシュであり、ディスクコントローラ11に対してリード・ライト処理球が発行されたときに使用される。そして、実際のリード・ライト処理は、このディスクキャッシュ13を経由して行われる。また、ディスクコントローラ12は、ディスクコントローラ11に障害が発生したときに、ディスクコントローラ11に障害が発生したときに、ディスクキャッシュ13がディスク媒体に書き戻す必要のな体に書き戻し、ディスクコントローラ11をディスク装置から切り放す機能を持つ。

【0060】図8は図7により説明するステップ1003でのリクエストの保留の処理を行うときの各ノードの動作を示し、図9は図7により説明するステップ1004でのディスクキャッシュの書き戻しの処理と、ステップ1005でのバッファキャッシュの転送の処理を行うときの各ノードの動作を示し、図10は図7により説明するステップ1006でのリクエストの保留解除及び転送の処理を行うときの各ノードの動作を示している。

【0061】以下、ディスクコントローラ11で障害が発生した時、物理ディスク装置10にアクセスするためのIOパスを"(200,290,11)"から"(300,390,12)"に切り替える処理を図8~図10を併用しながら図7に示すフローを参照して説明する。なお、論理ディスク管理テーブル270の設定は図2に示すようになっているものとする。

【0062】障害検出の処理(ステップ1001) ディスクコントローラ11に障害が発生すると、ディスクドライバ250は、IOパス(200,290,1 1)を使って物理ディスク装置10にアクセスを行うことができなくなる。これをもって障害検出とし、ディスクドライバ250は、IOパス(200,290,1 1)の障害発生をファイルサーバ240に通知する。また、ディスクドライバ250がローカルノードとしてのノード200のノード番号を含むIOパスのうち、論理ディスク管理テーブル270の状態フラグが、「使用中」状態及び「待機中」状態のIOパスを定期的に監視することによって障害を検出してもよい。これによっ

て、「待機中」状態のIOパスの障害検出が可能となる。

【0063】切り替え対象 I Oパスの検索の処理(ステップ1002)

障害発生通知を受けたファイルサーバ240は、図2に 示した論理ディスク管理テーブル270を参照し、障害 発生 I Oパス"(200, 290, 11)"を含むエン トリを検索する。そして、障害発生IOパスの状態フラ グが「待機中」状態であるか否かをチェックし(ステッ プ1010)、もし、障害発生IOパスの状態フラグが 「待機中」状態であれば、IOパスの切り替え処理は必 要なく、ステップ1011の処理に進む。そうでない場 合、IOパスの切り替えが必要になりステップ1103 の処理に進む。前述の検索によって見つかったエントリ には、障害発生 I Oパス以外に、状態フラグ279(2 75)が「待機中」状態のIOパス"(300,39 0, 12) "と論理ディスクID"123"が登録され ている。この「待機中」状態のIOパス"(300,3 90,12)"が切り替え先のIOパスとなる。ファイ ルサーバ240は、障害発生IOパス名と切り替え先の IOパス名とそれらに対応する論理ディスクID(以 後、IOパス切り替え処理を行う論理ディスクIDと呼 ぶ)を、ファイルサーバ240が管理するメモリ内に保 存し、ファイルサーバ240が論理ディスク管理テーブ ル270を検索することなくいつでも得られるようにし

【0064】リクエストの保留の処理(ステップ100 3)

この処理について、図8を参照して説明する。ファイルサーバ240は、現在処理中あるいは今後受理するIOアクセス要求の中で、IOパスの切り替え処理を行う論理ディスクID "123" あるいは障害発生IOパス "(200,290,11)"を指定したIOアクセス要求を保留し、その内容を後で取り出すことができるようにファイルサーバ240が管理するメモリ上に記録する。図8に示す例では、ファイルサーバ140は、ディスクコントローラ11で障害が発生したことを知らずに、論理ディスク "123"を指定したライト要求をファイルサーバ240に送信している。ファイルサーバ240は、このライト要求と、現在処理中のIOパス名 "(200,290,11)"を指定したリード要求を保留している。

【0065】次に、ファイルサーバ240は、切り替え 先のIOパス"(300,390,12)"に含まれる ノード番号"300"に対応するノード(以後、切り替 え先のノードと呼ぶ)のファイルサーバ340に、障害 発生IOパス名"(200,290,11)"と切り替 え先のIOパス名"(300,390,12)"と対応 する論理ディスクID"123"とを送信し、論理ディ スクIDを指定したIOアクセス要求を保留するように 要求する。この要求を受信したファイルサーバ340 は、前述の2つのIOパス名と論理ディスクIDとをファイルサーバ340が管理するメモリ上に保存し、これらの情報をいつでも得られるようにした後、論理ディスクID"123"を指定したIOアクセス要求を保留し、その内容を後で取り出せるようにファイルサーバ340が管理するメモリ上に保存する。図8に示す例では、ファイルサーバ340は、論理ディスクID"123"を指定したリード要求を保留している。

【0066】ディスクキャッシュの書き戻しの処理(ステップ1004)

この処理について、図9を参照して説明する。ファイルサーバ340は、リクエストの保留の設定を行った後、障害発生IOパスが含むディスクコントローラ番号"11"に対応するディスクコントローラ11が備えるディスクキャッシュ13を、切り替え先のIOパスが含むディスクコントローラ番号"12"に対応するディスクコントローラ番号"12"に対応するディスクコントローラ音号では表置に書き戻すようにディスクドライバ350は、IOインターフェイス390を介してディスクコントローラ12に制御信号を受けたディスクキャッシュ13に保存されているは1rtyなデータをディスク領域に書き戻し、ディスクコントローラ11をディスク装置10から切り放す。これらの処理の終了後、ディスクドライバ350は、ファイルサーバ340に終了通知を送る。

【0067】バッファキャッシュの転送の処理(ステップ1005)

この処理について、図9を用いて説明する。ファイルサ ーバ340は、ディスクドライバ350からの終了通知 を受けると、障害発生 I Oパス "(200, 290, 1 1) "に含まれるノード番号"200"に対応するノー ド (以後、障害発生ノードと呼ぶ)のファイルサーバ2 40にファイル管理テーブル260及びバッファキャッ シュ280の転送を要求する。ファイルサーバ340か らの要求を受信したファイルサーバ240は、dirt yな(物理ディスク装置に書き戻す必要のある)ファイ ル管理テーブル260とdirtyなバッファキャッシ ュ280の中で、論理ディスクID262や論理ディス クID281が、IOパス切り替え処理を行う論理ディ スク I D "123" であるデータを、ファイルサーバ3 40に送信する。この送信が成功したら、ファイルサー バ240は、ノード200内に存在する前述のデータを 消去可能とし、バッファキャッシュ280をしばらくの 間、読み出し用のキャッシュとして使用するが、バッフ ァキャッシュ280やファイル管理テーブル260のた めのメモリ領域が不足してきたらこれらを消去する。フ ァイルサーバ3.40は、受け取ったデータを、ノード3 00上のファイル管理テーブル360及びバッファキャ ッシュ380にマージする。ノード300上のこれらの

データはdirtyであるので、IOパスの切り替え処理が終了し通常運用状態となったら、ファイルサーバ 340が切り替え先のIOパス " (300, 390, 12)"を使用して物理ディスク装置 10に書き込む。また、前述の上記データは、読み出し用のキャッシュとして使用される可能性もある。

【0068】論理ディスク管理テーブルの更新の処理 (ステップ1006)

この処理は、図5により説明したフローの手順で実行さ れる。図5に示したローカルノードは、ここでは障害発 生ノード200である。ファイル管理テーブル260及 びバッファキャッシュ280の転送が終了すると、ファ イルサーバ240は、論理ディスク管理テーブル270 に登録されている障害発生IOパス"(200、29 0, 11) "の状態フラグ275を「使用中」状態から 「使用不可」状態に、切り替え先のIOパス"(30 0,390,12) "の状態フラグ279を「待機中」 状態から「使用中」状態に更新する。ファイルサーバ2 40は、論理ディスク管理テーブル270の更新の終了 後(図5のステップ901)、全リモートノードのファ イルサーバに論理ディスク管理テーブル270の更新情 報を送り、論理ディスク管理テーブルの更新を要求し (図5のステップ902)、リプライを待つ。例えば、 ファイルサーバ240からの要求を受信したノード10 0のファイルサーバ140は、受信した論理ディスク管 理テーブル270の更新情報に基づいて、ノード100 の論理ディスク管理テーブル170のIOパス"(20 0, 290, 11) "に対応する状態フラグ175を 「使用不可」状態に、 I Oパス "(300, 390, 1 2) "に対応する状態フラグ179を「使用中」状態に 更新する(図5のステップ906)。この更新の後、フ ァイルサーバ140は、ファイルサーバ240に論理デ ィスク管理テープル370の更新終了の通知を送る(図 5のステップ907)。ファイルサーバ240が、全リ モートノードのファイルサーバから論理ディスク管理テ ープルの更新終了の通知を受信すれば(図5のステップ 903)、システムを構成するすべてのノードの論理デ ィスク管理テーブルの更新が完了したことになる。

【0069】リクエストの保留解除及び転送の処理(ステップ1007)

この処理について、図10を参照して説明する。ファイルサーバ240は、切り替え先のノードのファイルサーバ340にリクエストの保留を解除する要求を送る。この要求を受けたファイルサーバ340は、ステップ1003で行ったIOアクセス要求の保留を解除し、保留していたIOアクセス要求の処理を行い、通常運用時の処理を開始する。また、ファイルサーバ240は、ステップ1003で行ったIOアクセス要求の保留を解除し、保留していたIOアクセス要求のうち、障害発生IOパスを指定したIOアクセス要求を、切り替え先のIOパスを指定したIOアクセス要求を、切り替え先のIOパ

スを指定したIOアクセス要求に変換した後、保留中のすべてのIOアクセス要求を、切り替え先のノードのファイルサーバ340に転送する。図10に示す例では、ファイルサーバ240は、IOパス"(200,290,11)"を指定したリード要求を、IOパス"(300,390,12)"を指定したリード要求に変換し、前述の要求と論理ディスクID"123"を指定したライト要求とをノード300のファイルサーバ340に転送している。転送されたIOアクセス要求は、ファイルサーバ340によって処理される。

【0070】マウント構成ファイルの更新の処理(ステップ1008)

最後に、ファイルサーバ240は、高信頼ディスク装置30が接続されているノード100のファイルサーバ140に障害発生IOパス"(200,290,11)"が「使用不可」状態になったことをマウント構成ファイル24に記載するように要求し、通常運用時の処理を開始する。この要求を受けたファイルサーバ140は、高信頼ディスク装置30上のマウント構成ファイル24を参照し、障害発生IOパス"(200,290,11)"の使用可否情報52を"unavailable"(使用不可)に書き換える。以上により、IOパスの切り替え処

【0071】論理ディスク管理テーブルの更新の処理 (ステップ1011)

理が終了する。

ステップ1010のチェックで、IOパスの切り替え処理を行う必要がなかった場合、障害発生ノードのファイルサーバ240は、ステップ1006の処理と同様の手順でシステム全体の論理ディスク管理テーブルを更新する。但し、障害発生IOパス"(200,290,11)"の状態フラグを「待機中」から「使用不可」に書き換える処理だけを行う。システム全体の論理ディスク管理テーブルの更新が終了した後前述したステップ1008の処理に進む。

【0072】図11はIOパスが障害から復旧したとき、IOパスをシステムに復旧させる処理手順を説明するフローチャートであり、これについて説明する。ここでは、物理ディスク装置10のディスクコントローラ11の障害などの原因により「使用不可」状態になっていたIOパス"(200,290,11)"がディスクコントローラ11の交換などによって再び使用可能になったとき、システムに上記のIOパスを復旧させる方法を例に説明する。また、ここでは、IOパスの復旧処理中に使用中のIOパスに障害が発生することはないと仮定する

【0073】(1)障害が発生したディスクコントローラの交換等により、今まで使用不可能となっていた IOパス"(200, 290, 11)"が使用可能な状態になると、システム管理者は、管理用のプログラムを使って、この IOパスをシステムに復旧させる要求を、高信

頼ディスク装置が接続されているノード100のファイルサーバ140に送信する。ファイルサーバ140は、 この要求を受信する(ステップ601)。

【0074】(2)復旧要求を自したファイルサーバ140は、論理ディスク管理テーブル170を参照して、前述のIOパス"(200,290,11)"の状態フラグ175を「使用不可」状態から「待機中」状態に更新する。また、ファイルサーバ140は、論理ディスク管理テーブル170の更新が終了したら、全ての稼働中のノードのファイルサーバと通信を行い、全ノードの論理ディスク管理テーブルを論理ディスク管理テーブル170と同じ内容にする。この処理は、図7によるIOパスの切り替えのフローにより説明したステップ1006での処理と同様な処理により行われる(ステップ602)。

【0075】(3) そして、ファイルサーバ140は、高信頼ディスク装置30上のマウント構成ファイル24を参照し、前述のIOパス"(200,290,11)"の使用可否情報52を"unavailable"(使用不可)から"available"(使用可)に変更する。前述の処理により、IOパス"(200,290,11)"を「待機中」状態としてシステムに復旧させることができる(ステップ603)。

【0076】前述した本発明の実施形態は、ファイル管 理テープル260及びバッファキャッシュ270をノー ド200からノード300に転送するとして説明した (図7のステップ1005)が、これは次のような理由 による。すなわち、物理ディスク装置へのアクセスは、 ローカルノードからのアクセスでもリモートノードから のアクセスでも、最終的に、その物理ディスク装置が接 続されたノードのファイル管理テーブル及びバッファキ ャッシュを経由して行われる。従って、物理ディスク装 置が接続されたノードは、そのノード(ローカルノー ド)で動作するプログラムに関係するファイル管理テー ブル及びバッファキャッシュの他に、リモートノードで 動作するプログラムに関係するファイル管理テーブル及 びバッファキャッシュを持つ。前述した本発明の実施形 態に示したようなIOパス切り替え処理は、物理ディス ク装置が接続されているノードがノード200からノー ド300に切り替わるので、ノード300がノード20 0に代わって、ノード200が保持していたファイル管 理テーブル260及びバッファキャッシュ280を持つ 必要がある。そこで、IOパス切り替え処理時にファイ ル管理テーブルやバッファキャッシュをノード300に 転送するようにしている。このとき、dirtyなデー タのみを転送するようにして、データの転送量をなるべ く少なく済むようにしている。

【0077】また、前述した本発明の実施形態は、物理ディスク装置10、20を共にノード200から使用しているときに、IOインターフェイス290に障害が発

生した場合、IOパス(200, 290, 11)及び (200, 290, 21) の両方が使用できなくなる が、この場合、ディスクドライバ250が、各々のIO パスに対して障害検出を行い、各々のIOパスに対して 前述の各ステップで示されるIOパスの切り替え処理を 行うようにすればよい。また、ディスクドライバ250 がIOインターフェイス290で障害が起こったことを 検出する機能を持つ場合、ステップ1001で、ディス クドライバ250がファイルサーバ240にIOインタ ーフェイス290の障害を通知し、ステップ1002 で、ファイルサーバ240が論理ディスク管理テーブル 270を検索し、障害発生 I Oインターフェイス番号 "290"から、障害発生IOパス(200, 290, 11)、(200, 290, 21)と対応する切り替え 先のIOパスと論理ディスクIDを探し出し、これら2 組のIOパスについて、前述の各ステップで示される切 り替え処理を同時に行うようにしてもよい。

【0078】前述した本発明の実施形態において、ノー ド200が2つのIOインターフェイスを有し、物理デ ィスク装置10がこれら2つのIOインターフェイスに よってノード200と接続されており、物理ディスク装 置10とノード200との間のIOパスが2つ存在し、 通常運用時これらの I Oパスのうち1つを利用している ような場合、ディスクコントローラやIOインターフェ イスの障害発生により、今まで使用していたIOパスが 使用できなくなったとき、物理ディスク装置10にアク セスするためのIOパスをもう片方のIOパスに前述し たの方法で切り替えることができる。この場合、ステッ プ1003でノード300のファイルサーバ340がⅠ Oアクセス要求を保留する処理と、ステップ1005で ノード200が持つバッファキャッシュ280及びファ イル管理テーブル260をIOパス切り替え先のノード 300に転送する処理が不要となる。

【0079】また、本発明は、物理ディスク装置にアク セスするための I Oパスが 3 つ以上存在する場合にも適 用することができる。この場合、論理ディスク管理テー ブル及びマウント構成ファイル24の各エントリに3つ 以上のIOパスの組を登録できるようにし、システムの 起動時にファイルサーバ140がマウント構成ファイル 24に記載されたIOパスの組に対して、1つの論理デ ィスクIDを設定し、IOパスと論理ディスクIDとの 対応関係を論理ディスク管理テーブルに登録するように すればよい。そして、この場合、通常運用時、複数のI Oパスが「待機中」状態としてスタンバイするため、障 害発生時のIOパスの切り替え処理を行う際に、複数の 「待機中」状態のIOパスの中から切り替え先のIOパ スを選択する必要がある。この切り替え先のIOパスの 決定は、前述した実施形態におけるステップ1002で 障害を検出したノードのファイルサーバがそのノードの 論理ディスク管理テーブルを検索し、障害発生IOパス

名を含むエントリを見つけたときに、そのエントリのなるべく最初の方のフィールドに登録されている「待機中」状態のIOパスを切り替え先のIOパスとして選び出すことによって行うようにすればよい。また、論理ディスク管理テーブルに登録されている各IOパス毎に使用時間(状態フラグが「使用中」状態となっていた時間)を上記論理ディスク管理テーブルに登録できるようにし、IOパスの切り替え処理時、使用時間の短いIOパスに切り替えるようにしてもよい。これによって、複数のIOパスをまんべんなく使用することができる。

【0080】さらに、本発明は、LAN等のネットワークにより接続された疎結合計算機システムによるファイルシステムに対しても適用することができる。この場合、前述のノード番号の代わりにネットワークアドレスを使用すればよい。

【0081】また、前述した本発明の実施形態において、ディスクキャッシュ13をディスクコントローラ12から制御し、ディスク装置10に書き戻す機能を物理ディスク装置10が持たない場合、ノード200のディスクドライバ250が、ディスクキャッシュ13に保存されたdirtyなキャッシュを少なくとも含むデータを予め保持しておいて、障害発生時、前述のステップ1004でディスクドライバ250がディスクドライバ350と通信を行い、dirtyなディスクキャッシュを少なくとも含むようなデータをノード200からノード300に転送し、ディスクコントローラ12を通してディスク装置10に書き戻すようにしてもよい。

【0082】前述した本発明の実施形態は、IOパス切り替え処理中、障害発生ノード及び切り替え先のノードに送信されてきたIOアクセス要求は、保留するようにしていたが、IOアクセス要求を保留しないようにすることもできる。以下、この場合のファイルサーバの動作について図面により説明する。

【0083】図12はIOパス切り替え時の障害発生ノードの処理動作の他の例について説明するフローチャート、図13は障害発生ノード以外のノードの処理動作の他の例を説明するフローチャートである。以下、障害発生ノードがノード200、切り替え先のノードがノード300の場合を例として、図12、図13に示すフローを参照して、IOパス切り替え処理中に各ノードに送信されてきたIOアクセス要求の処理の方法を説明する。まず、障害発生ノードのファイルサーバの動作を図12のフローにより説明する。

【0084】(1)障害発生ノードのファイルサーバ240は、IOパス切り替え処理中に、IOアクセス要求を受信すると、その要求が他のノードであるリモートノードからの要求が否かを判定する(ステップ701、702)。

【0085】(2)ステップ702の判定で、受信した 【Oアクセス要求がローカルノード(自ノード)のユー ザアプリケーション 230 からのものであると判定すると、ファイルサーバ 240 は、前述した実施形態で説明したと同様に、I 〇パス切り替え処理の間、その要求を保留する。この要求は、I 〇パスの切り替え処理終了時に、切り替え先のノードに送信される(ステップ 70 3)。

【0086】(3) ステップ702の判定で、受信した I Oアクセス要求がリモートノードからのものであると 判定すると、ファイルサーバ240は、その要求に対し てリプライを返さずに無視する(ステップ704)。

【0087】次に、障害発生ノード以外のノードのファイルサーバの動作を図13に示すフローを参照して説明する。障害発生ノード以外のファイルサーバは、基本的に図4により説明した通常運用時と同様の動作をするので、ここでは図4の処理と重なる部分については説明を省略する。

【0088】(1)障害発生ノード以外のファイルサーバがIOパス切り替え中に障害発生ノード(ノード200)に送信したIOアクセス要求はタイムアウトとなる(ステップ808)。

【0089】(2) IOアクセス要求がタイムアウトになったら、IOアクセス要求を送信したファイルサーバは、一定時間(例えば1秒)待った後、論理ディスク管理テーブルを参照して、論理ディスクIDからIOパス名を求める処理から処理をやり直す。このとき、IOパスの切り替え処理が終了していれば、全ノードの論理ディスク管理テーブルが更新されているので、ステップ8040処理によって切り替え先のIOパスが求まる(ステップ804)。

【0090】 (3) IOアクセス要求を送信しようとしているファイルサーバは、求められたIOパス名が含むノードがローカルノードであるか否かを判定し、切り替え先のIOパス名が含むノードがローカルノードでなかった場合、IOアクセス要求を切り替え先のノード(ノード300)に送信する(ステップ805、806)。【0091】 (4) ステップ805の判定で、切り替え先のIOパスがローカルノードであれば、IOアクセス要求を送信しようとしているファイルサーバは、IOアクセス要求をローカルノードのディスクドライバに送信する(ステップ807)。

【0092】前述したステップ804の処理において、もし、論理ディスクIDからIOパス名を求めなおしたときに、IOパスの切り替え処理が終了していない場合、IOアクセス要求は、障害発生ノード(ノード200)に送信され、上記IOアクセス要求は再びタイムアウトとなり、IOアクセス要求が成功するまで前述した処理が繰り返される。

【0093】この方法を使用することにより、図7により説明したステップ1003のリクエストの保留処理でリモートノードからのアクセス要求を保留する必要がな

くなるので、IOアクセス要求を保留するためのメモリを節約することができる。また、IOアクセス要求の再送回数に制限(例えば5回)を設け、もし制限回数だけ再送を行ってもタイムアウトになり続ければ、そのIOアクセス要求をエラーとしてもよい。また、IOパス切り替え処理中、障害発生ノードのファイルサーバ240は、リモートノードからのIOアクセス要求を無視するかわりに、「IOパス切り替え処理中なので、IOアクセス要求を処理できない」という意味の通知をアクセス要求を必要できない」という意味の通知をアクセス要求を送信したリモートノードのファイルサーバに送信するようにしてもよい。これにより、リモートノードのファイルサーバは、IOパスで障害が発生した場合とクード200で障害が発生した場合とを区別することができるようになる。

【0094】前述までに説明した本発明の第1の実施形態によるIOパス切り替え方法は、ノード200でOSの障害が発生したとき、ネットワーク1を通じてバッファキャッシュ280やファイル管理テーブル260をノード300に転送することができなくなるため、同じ方法でIOパスの切り替えを行うことは不可能である。

【0095】これを解決するため、本発明は、バッファキャッシュ280やファイル管理テーブル260をノード300に転送するための専用のハードウェアを使う方法を取ることができる。以下、これを第2の実施形態として説明する。

【0096】図14は本発明の第2の実施形態によるディスクキャッシュの書き戻しの処理とバッファキャッシュの転送の処理とを説明する図である。

【0097】本発明の実施形態におけるIOパス切り替え処理の手順は、前述までに説明した第1の実施形態の場合の図7に示すフローと同様に行われる。但し、第2の実施形態では、ステップ1003及びステップ1007の処理は行わない。そして、図14には、ステップ1004でのディスクキャッシュの書き戻しの処理とステップ1005でのバッファキャッシュの転送の処理についてしめしている。

【0098】図14において、メモリアクセス手段299(399)は、ノード200(300)に付属しており、メモリアクセス手段299とメモリアクセス手段399とは専用通信線2によって互いに接続されている。メモリアクセス手段299は、ノード200でOSの障害が発生しノード200上で動作するプログラムの全てが停止した場合にも、メモリ220にアクセスし、その内容を専用通信線2を使用してメモリアクセス手段399との通信によりノード300に送信することが可能なハードウェアである。

【0099】通常運用時、図14に示す各ノードのファイルサーバは、図13により説明した動作を行う。ここで例えば、ノード200でOSの障害が発生したとすると、あるファイルサーバがノード200に送信したIO

アクセス要求のリプライが戻ってこないので、IOアクセスを送信したファイルサーバは、上記IOアクセス要求をタイムアウトにする(ステップ808)。ファイルサーバは、一定時間待った後、ローカルノードの論理ディスク管理テーブルを参照し、論理ディスクIDからIOパスを求める処理から処理の再実行を行うことになる(ステップ804)。IOパス切り替え処理中、前述の要求は、障害発生ノード(ノード200)に送信されタイムアウトとなるが、IOパス切り替え終了後、要求は切り替え先のノードに送信される。

【0100】以下、ノード200で障害が発生しノード200で動作する全てのプログラムが停止した場合に、物理ディスク装置10にアクセスするためのIOパスを(200,290,11)から(300,390,12)に切り替えるものとして、その処理を図1、図2、図14を併用しながら図7に示すフローを参照して説明する。

【0101】障害検出の処理(ステップ1001)
ノード200で障害が発生すると、ノード200は、リクエストを一切受け付けなくなる。従って、ノード200にIOアクセス要求を送信したリモートノードのファイルサーバは、IOアクセス要求をタイムアウトとする。IOアクセス要求を送信したファイルサーバは、このタイムアウトによってノード200で障害が発生したことを検出する。前述したように、IOアクセス要求がタイムアウトになったらその要求を再送するので、何度も障害発生ノード(ノード200)に上記要求を再送し、そのたびに要求をタイムアウトにする可能性がある。上記ファイルサーバは、あるノードへの要求が最初にタイムアウトになったとき、次のステップ1002の処理に進み、2回目以降、ステップ1002以降の処理は行わない。

【0102】切り替え対象IOパスの検索の処理(ステップ1002)

I Oアクセス要求を送信したファイルサーバは、ローカルノードの論理ディスク管理テーブルを参照し、障害が発生したノードのノード番号"200"から障害発生I Oパス名と切り替え先のI Oパス名とを探し出し、切り替え先のI Oパスが含むノード番号に対応するノード

(切り替え先のノード)のファイルサーバに、障害発生 I Oパスから切り替え先の I Oパスに I Oパスを切り替えるように要求する。切り替え先のノードがローカルノード(自ノード)であれば、I Oアクセスを送信したファイルサーバは、直ちに I Oパスの切り替えの処理を開始する。但し、障害発生 I Oパスの状態フラグが「待機中」状態の場合(ステップ1010)、I Oパスの切り替え処理は必要なくステップ1011の処理に進む。例えば、ノード100のファイルサーバ140がノード200のファイルサーバ240に送信した I O処理要求がタイムアウトとなった場合、ファイルサーバ140は、

図2に示した論理ディスク管理テーブル170を検索し、ノード番号"200"を含むエントリを探す。見つかったエントリには複数のIOパスが記載されているが、ノード番号"200"を含むIOパス"(200,290,11)"が障害発生IOパスであり、状態フラグが「待機中」状態でノード番号"200"を含まないIOパス"(300,390,12)"が切り替え先のIOパスである。障害発生IOパスの状態フラグ275が「使用中」状態であるので、ファイルサーバ140は、切り替え先のノード300のファイルサーバ340に"(200,290,11)"から"(300,390,12)"にIOパスを切り替えるように要求する。もし、上記障害発生IOパスの状態フラグが「待機中」状態であれば、IOパスの切り替え処理は必要なく、ステップ1011の処理に進む。

【0103】前述した検索処理で、切り替え処理を行う IOパスの組が複数個見つかった場合、障害を検出した ファイルサーバは、IOパス毎に対応する切り替え先の ノードのファイルサーバに I Oパスの切り替え要求を送 信する。但し、複数のIOパスの切り替え要求を1つの ノードに送る必要がある場合、それらのIOパスの切り 替え要求を一括して送り、切り替え先のノードのファイ ルサーバが、それらのIOパスの切り替え処理を同時に 行う。例えば、物理ディスク装置10と物理ディスク装 置20とをノード200から使用していた場合、ノード 200の障害を検出したファイルサーバは、ノード30 0のファイルサーバ340に上記2つの物理ディスク装 置にアクセスするための2組のIOパスを切り替える要 求を発行し、ファイルサーバ340は、前述した2組の IOパスの切り替え処理を同時に行う(ステップ100 $4 \sim 1008)$.

【0104】ディスクキャッシュの書き戻しの処理(ステップ1004)

障害発生 I Oパス"(200,290,11)"から切り替え先のI Oパス"(300,390,12)"にI Oパスを切り替えるように要求されたファイルサーバ340は、I Oパスの切り替えモードに入り、その後再び同じI Oパス切り替え要求が送られてきても受理しない。これによって、I Oパスの切り替え処理が二重に行われることを防止する。このステップの処理の後の処理内容は、第1の実施形態の場合と同様に行われる。ファイルサーバ340は、図14に示すように、ディスクドライバ350にディスクキャッシュの書き戻し要求を送信することにより、ディスクキャッシュ13の内容をディスク領域に書き戻して、ディスクコントローラ11を物理ディスク装置から切り放す。

【0105】バッファキャッシュの移動の処理(ステップ1005)

ファイルサーバ340は、次に、図14に示すように、メモリアクセス手段399に、障害が発生したノード2

00のファイル管理テーブル260とバッファキャッシュ280との内容をローカルノード(ノード300)に転送するように要求する。メモリアクセス手段399は、メモリアクセス手段299と通信を行い、専用通信線2を介して、dirtyなバッファキャッシュ280及びdirtyなファイル管理テーブル260の内容をノード300のファイルサーバ340に転送する。ファイルサーバ340は、ノード300上のファイル管理テーブル360及びバッファキャッシュ380にメモリアクセス手段399から送られてきたデータをマージする。マージされたデータは、IOパスの切り替え先のIOパスから物理ディスク装置10に書き込まれる。また、これらデータは、読み出し用のキャッシュとしても使われる可能性もある。

【0106】論理ディスク管理テーブルの更新の処理 (ステップ1006)

データの転送処理が終了した後、ファイルサーバ340は、論理ディスク管理テーブル370に登録されているIOパスの状態フラグを、障害発生IOパス"(200,290,11)"について、「使用不可」状態に、切り替え先のIOパス"(300,390,12)"について、「使用中」状態に登録し直す。ファイルサーバ340は、論理ディスク管理テーブル370の更新の終了後、第1の実施形態の場合と同様な方法により、全ての稼働中のノードのファイルサーバと通信を行うことにより、全ての稼働中のノードの論理ディスク管理テーブルに登録されている、障害発生IOパスの状態フラグを「使用不可」状態に、切り替え先のIOパスの状態フラグを「使用不可」状態に更新する。

【0107】マウント構成ファイルの更新の処理(ステップ1008)

ファイルサーバ340は、全ての稼働中のノードの論理ディスク管理テーブルの更新が終了した後、高信頼ディスク装置30が接続されているノード100のファイルサーバ140に、IOパス"(200,290,11)"が「使用不可」状態になったことをマウント構成ファイル24に記載するように要求し、IOパスの切り替えモードから抜け、通常運用時の処理を開始する。前述の要求を受けたファイルサーバ140は、「使用不可」状態となったIOパス"(200,290,11)"の使用可否情報52を"available"(使用可)から"unavailable"(使用不可)に更新する。以上によりIOパスの切り替え処理が終了する。

【0108】論理ディスク管理テーブルの更新の処理 (ステップ1011)

ステップ1010で、障害発生パスが「待機中」状態にあると判定され、IOパスの切り替え処理を行う必要がない場合、ステップ1001の処理で障害を検出したファイルサーバは、ステップ1006の処理と同様の手順

でシステム全体の論理ディスク管理デーブルを更新する。但し、障害発生IOパスの状態フラグを「使用不可」に書き換える処理だけを行う。システム全体の論理ディスク管理テーブルの更新が終了した後、前述のファイルサーバがファイルサーバ140に対してマウント構成ファイルの更新を要求し、この要求を受けたファイルサーバ140は、ステップ1008の処理を行う。

【0109】図15は本発明の第3の実施形態によるファイルシステムの構成を示すプロック図、図16は本発明の第3の実施形態におけるマウント構成ファイルの具体的な構成例を説明する図であり、図15における符号は図1の場合と同一である。図15に示す本発明の第3の実施形態は、同一のファイルを物理ディスク装置10と物理ディスク装置20とに二重化(ミラーリング)して記録する例である。

【0110】図示本発明第3の実施形態において、マウ ント構成ファイルの1つのエントリには、図16に示す ように、物理ディスクにアクセスするためのIOパス名 51、53、各10パスの使用可否情報52、54、マ ウントポイント55が記載されている。この第3の実施 形態は、マウントポイントの1つのエントリに記載され たIOパスからアクセスされる物理ディスク装置にファ イルが多重化して記録される。従って、前述のIOパス からアクセスされる物理ディスク装置は異なるものであ る必要がある。図16に示す例では、/mnt ディレクト リ以下のディレクトリに格納されたファイルは、IOパ ス"(200, 290, 11)"、"(300, 39 0, 22) "からアクセスされる物理ディスク装置(物 理ディスク装置10、20)にミラーリングされる。こ のような指定方法を採用することにより、システム管理 者が論理ボリュームの設定を行う必要がなくなる。

【0111】システム立ち上げ時、ファイルサーバ140は、マウント構成ファイル24を読み込んで、第1の実施形態の場合と同様の手順で、全てのノードの論理ディスク管理テーブルを設定する。但し、第3の実施形態では、ファイルサーバ140は、マウント構成ファイル24の使用可否情報に"available"(使用可)と記載されているすべてのIOパスについて、論理ディスク管理テーブルの対応する状態フラグに「使用中」と登録する。

【0112】次に、通常運用時のファイルサーバの動作を、ノード100のユーザアプリケーション130がファイルID"100"を指定したファイルアクセス要求をファイルサーバ140に発行した場合を例に、図15、図16を参照し、図6に示すフローに基づいて説明する。なお、ファイル管理テーブルの設定は図2、論理ディスク管理テーブルの設定は図16に示すようになっているものとする。

【0113】(1)ファイルサーバ140は、ユーザア プリケーション130がらファイルIDを指定したアク セス要求を受けると、その要求がリモートノードからの要求であるか否かを判定し、自ノードからの要求である場合、ファイル管理テーブル160を検索し、ファイル ID "100" から論理ディスク ID "123" を求める (ステップ 501~503)。

【0114】(2) そして、ファイルサーバ140は、 論理ディスク管理テーブル170を検索し、論理ディス クID"123"から状態フラグが「使用中」状態のI Oパス名"(200, 290, 11)"、"(300, 390, 22)"を求める(ステップ504)。

【0115】(3)アクセス要求がライト要求の場合は、前述の両方のIOパスに対して同一内容の書き込みを行う。このため、ファイルサーバ140は、前記2つのIOパス名が含むノードがローカルノードか否かを判定し、ローカルノードでない場合、すなわちリモートノードである場合、2つのIOパスが含むノード番号に対応するノード(ノード200、ノード300)のファイルサーバ240、340にIOパス名を指定したライト要求を送信する(ステップ505、506)。

【0116】 (4) ステップ505での判定が、ノードがローカルノードであった場合、ローカルノードのディスクドライバに IOパスを指定したライト要求を送信する(ステップ507)。

【0117】図15に示す例の場合、前述の処理で、ファイルサーバ140は、ファイルサーバ240にIOパス"(200,290,11)"を指定したライト要求を送信し、ファイルサーバ340にIOパス"(300,390,22)"を指定したライト要求を送信する。これらのライト要求を受信したファイルサーバ240、340は、それぞれのノードのディスクドライバにIOパスを指定したライト要求を送信する。

【0118】受信したアクセス要求がリード要求の場合、ファイルサーバ140は、前述したIOパスのうちで、論理ディスク管理テーブルの最も最初のフィールドに登録されていたIOパス"(200,290,11)"を使用してアクセスを行う。もし、IOパスの障害などの理由により、このIOパスを使用してアクセスすることができない場合、順に次のフィールドに登録されているIOパスを使用してアクセスを試みる。また、前述のIOパスの中で、ローカルノードのノード番号を含むものがあれば、そのIOパスを最初に使うようにしてもよい。このように、なるべくリモートアクセスを減らすことによって、ネットワークの負荷を減らすことができる。リード処理に使用するIOパスが決定した後の処理は、ライト要求の場合と同様である。

【0119】次に、障害発生時、障害が発生したIOパスを切り放す処理を説明する。ここでは、ディスクコントローラやIOインターフェイスの障害により、ノード200に接続されていた物理ディスク装置20にアクセスするためのIOパス"(200,290,11)"が

使用不可能になったものとして説明する。

【0120】障害の発生により、IOパス"(200,290,11)"が使用できなくなった場合、ノード200のデバイスドライバ250は、このIOパスの障害を検出し、障害発生をファイルサーバ240に通知する。

【0121】この通知を受けたファイルサーバ240は、論理ディスク管理テーブル270を更新し、障害発生IOパスの状態フラグを「使用不可」状態にする。ファイルサーバ240は、図5に示したフローによる方法により、全てのリモートノードのファイルサーバと通信を行い、全てのノードの論理ディスク管理テーブルを論理ディスク管理テーブル270と同一の内容に更新する。

【0122】最後に、ファイルサーバ240は、高信頼ディスク装置30が接続されたノード100のファイルサーバ140に、障害発生IOパス"(200,290,11)"が「使用不可」状態になったことを、マウント構成ファイル24に記載するように要求する。この要求を受けたファイルサーバは、マウント構成ファイル24を更新し、上記障害発生IOパスの使用可否情報を"unavailable"(使用不可)に書き換える。以上によりIOパスの切り離しが終了する。

【0123】IOパスの切り離し処理中に、あるノードのファイルサーバ(例えば、ファイルサーバ140)が、ファイルサーバ240に前述の障害発生IOパスを指定したアクセス要求を送るとその要求は失敗する。しかし、ライト処理の場合、データは、同時に複数の物理ディスク装置に書き込まれるので、アクセス可能な物理ディスク装置(物理ディスク装置20)の方に無事に記録されている。また、リード処理の場合、アクセス要に失敗したら別のIOパス"(300,390,22)"を指定したIOアクセス要求をファイルサーバ340に送信する。このため、データは、アクセス可能な物理ディスク装置からため、データは、アクセス可能な物理ディスク装置からため、データは、アクセス可能な物理ディスク装置から無事に読み込まれる。従って、IOパス切り替え中もユーザは、それを意識することなくファイルにアクセスすることができる。

【0124】前述した本発明の実施形態において、ノード200で障害が発生したことにより、IOパス"(200,290,11)"が使用できなくなった場合、ノード200にIOアクセス要求を送信したリモートノードのファイルサーバが、送信したアクセス要求のタイムアウトによってノード200の障害を検出し、障害を検出したこのファイルサーバが上記のIOパスの切り離し処理を行うようにすればよい。

【0125】また、前述した本発明の実施形態において、論理ディスク管理テーブルに、論理ディスクの使用方法(切り替え、ミラーリングなど)を指定するためのディスクタイプ情報を論理ディスクID毎に登録できる

ようにし、マウント構成ファイル24に上記ディスクタ イプ情報を登録できるようにし、システム起動時にファ イルサーバ140がマウント構成情報24に記載された ディスクタイプ情報を、論理ディスク管理テーブルのデ ィスクタイプ情報に登録し、通常運用時及び障害発生 時、ファイルサーバが論理ディスク管理テーブルのディ スクタイプ情報によって、ディスクタイプを判別し各デ ィスクタイプ毎の処理を行うようにすることもできる。 例えば、図15に示す例の場合、マウント構成ファイル 24には"((200, 290, 11) available) ((300, 390, 22) available) /mnt mirro r"と記載する。"mirror"は、前述2つのIOパスか らアクセスされる物理ディスク装置に対して、ミラーリ ングを行うことを示す。ファイルサーバ140は、起動 時に前述のエントリを読み込んで、ディスクタイプが 「ミラーリング」であることを判別し、論理ディスク管 理テーブルの対応するディスクタイプ情報に、「ミラー リング」であることを登録する。通常運用時、ファイル サーバは、論理ディスク管理テーブルのディスクタイプ 情報を参照して、前述のIOパスの組が「ミラーリン グ」を行うものであることを判別すると、前述した実施 形態により説明した「ミラーリング」の処理を行う。デ

【0126】前述した本発明の第3の実施形態は、ファイルのミラーリングを行うものとして説明したが、論理ディスク管理テーブルの1つのエントリに登録されたIOパスからアクセスされる物理ディスク装置に、ファイルを分散して記録するようにすれば、ファイルのストライピングを行うことができる。

ィスクタイプが「切り替え」の場合も同様である。これ

により、IOパスの切り替えとミラーリングをシステム

[0127]

で共存させることができる。

【発明の効果】以上説明したように本発明によれば、IOパス切り替え・復旧処理のためにかかる時間を短縮することができ、また、IOパス切り替え時にファイルの整合性のチェックを不要にすることができる。また、本発明によれば、IOパスの切り替え・切り離し処理が発生しても、一般ユーザはそれを意識することなく作業を続けることができる。さらに、本発明によれば、IOパス切り替え・切り離し処理後あるいは障害発生IOパス切り替え・切り離し処理後あるいは障害発生IOパス復旧後、システムを再起動する際にシステム管理者がマウント構成ファイルを設定しなおす必要をなくすことができ、システム管理者の負担を軽減することができる。

【図面の簡単な説明】

【図1】本発明の第1の実施形態によるファイルシステムの構成を示すブロック図である。

【図2】システム内に設けられる各種のテーブルの具対的な構成例を説明する図である。

【図3】マウント構成ファイルの具体的な構成例を説明する図である。

【図4】システムの起動時のファイルサーバの処理動作を説明するフローチャートである。

4•> .

【図5】システム全体のノードの論理ディスク管理テーブルを更新する処理動作を説明するフローチャートである。

【図6】通常運用時のファイルサーバの処理動作を説明 するフローチャートである。

【図7】 I Oパスの切り替えの処理動作を説明するフローチャートである。

【図8】IOパスに障害が発生しIOパスの切り替えを 行う処理について説明する図(その1)である。

【図9】IOパスに障害が発生しIOパスの切り替えを 行う処理について説明する図(その2)である。

【図10】IOパスに障害が発生しIOパスの切り替えを行う処理について説明する図(その3)である。

【図11】 I Oパスが障害から復旧したとき、 I Oパスをシステムに復旧させる処理手順を説明するフローチャートである。

【図12】IOパス切り替え時の障害発生ノードの処理 動作の他の例について説明するフローチャートである。

【図13】障害発生ノード以外のノードの処理動作の他の例を説明するフローチャートである。

【図14】本発明の第2の実施形態によるディスクキャ

ッシュの書き戻しの処理とバッファキャッシュの転送の 処理とを説明する図である。

【図15】本発明の第3の実施形態によるファイルシステムの構成を示すプロック図である。

【図16】本発明の第3の実施形態におけるマウント構成ファイルの具体的な構成例を説明する図である。

【符号の説明】

1 ネットワーク

10、20、30 物理ディスク装置

11、12、21、22 ディスクコントローラ

13 ディスクキャッシュ

24 マウント構成ファイル

100、200、300 ノード

110, 210, 310 CPU

120、220、320 メモリ

130、230 ユーザアプリケーション(UAP)

140、240、340 ファイルサーバ (FS)

160、260 ファイル管理テーブ

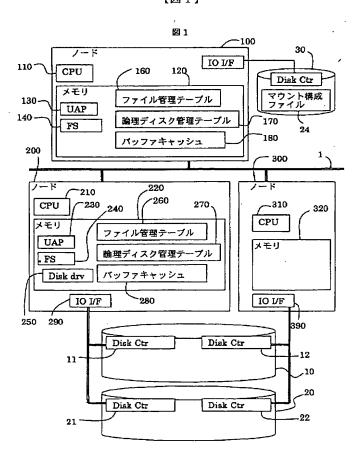
170、270 論理ディスク管理テーブル

180、280、360 バッファキャッシュ

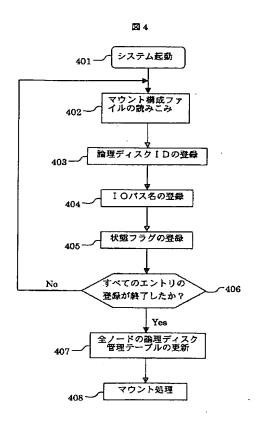
250、350 ディスクドライバ

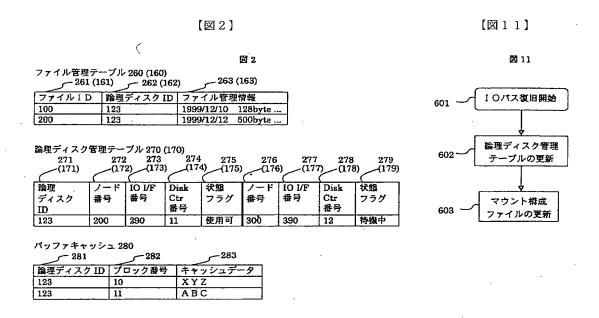
290、390 ΙΟインタフェース

【図1】



【図4】



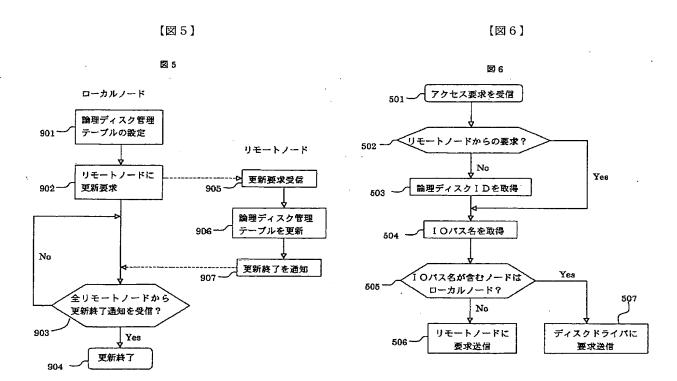


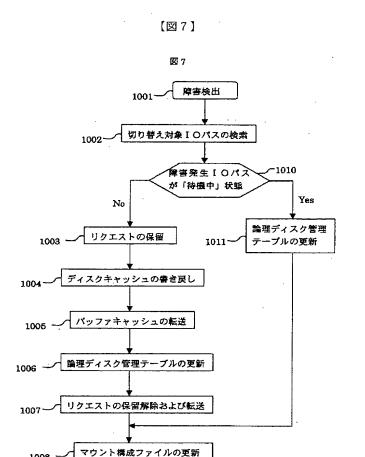
【図3】

図 3

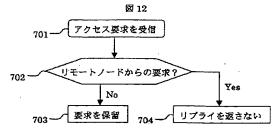
マウント構成ファイル24

((ノード番号, IO I/F 番号, Disk Ctr 番号) 使用可否) マウントポイント ← コメント行 ((200, 290, 11) available) ((300, 390, 12) available) /mnt

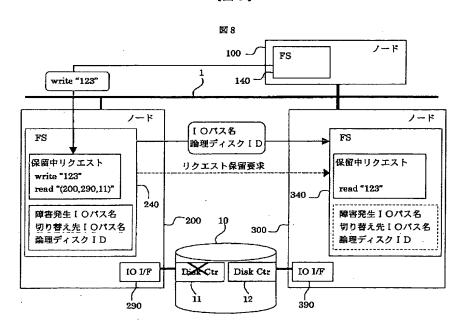




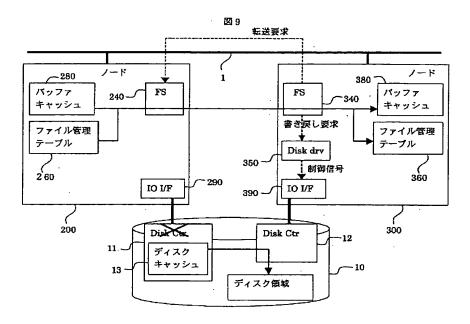
【図12】



[図8]

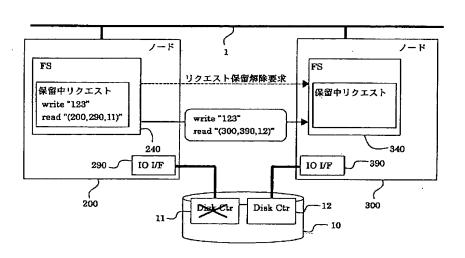


【図9】

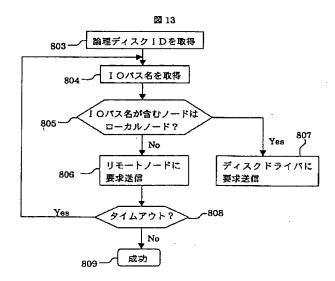


【図10】

図 10

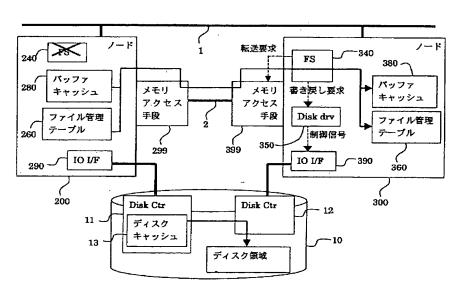


【図13】



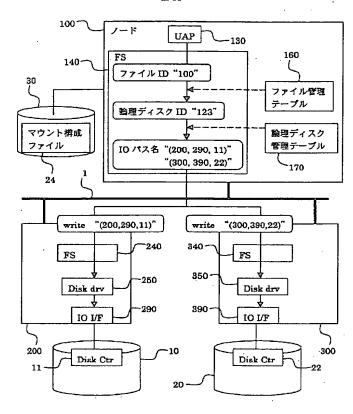
【図14】

図 14



【図15】

図 15

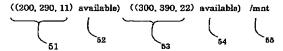


【図16】

図 16

マウント構成ファイル24

((ノード番号, IO I/F 番号, Disk Ctr 番号) 使用可否) マウントポイント **←** コメント行



論理ディスク管理テーブル 270 (170)

(171)	272		274		276	277	278 (178	279 (179)
論理 ディスク ID	ノード 番号	IO I/P 番号	Disk Ctr 番号	状態 フラグ	ノード 番号	IO I/F 番号	Disk Ctr 番号	状態 フラグ
123	200	290	11	使用可	300	390	22	使用可

フロントページの続き

(72)発明者 薗田 浩二

神奈川県川崎市麻生区王禅寺1099番地 株 式会社日立製作所システム開発研究所内

(72)発明者 熊△崎▽ 裕之

神奈川県横浜市戸塚区戸塚町5030番地 株 式会社日立製作所ソフトウェア事業部内 Fターム(参考) 5B014 HA09 HA13 HB01 HB26 5B018 GA10 HA40 KA11 MA12 QA01 5B065 CC01 EA12 5B082 EA01 FA05 5B083 AA08 BB03 CC04 CD11 EE08